

PEMETAAN VARIETAS PADI DENGAN LINEAR SPECTRAL UNMIXING

Lalu Muhammad Jaelani



QRCBN : 62-10672-9288-328

GEOITS PRESS

Oktober, 2026

Pemetaan Varietas Padi dengan Linear Spectral Unmixing

Penulis: Lalu Muhamad Jaelani
Desain cover dan Lay Out: TIM GEOiTS PRESS
Diterbitkan oleh: GEOiTS PRESS

Alamat:
Laboratorium Geospasial, Gedung Teknik Geomatika, Kampus ITS,
Sukolilo, Surabaya 60111
Email: carpathacademy@gmail.com
Website: <https://geo.its.ac.id/book/>
Hp. 085156117445

Tahun Cetak: Oktober, 2026

QRCBN: 62-10672-9288-328

Buku ini dilisensikan di bawah Lisensi Creative Commons Atribusi
NonKomersial-BerbagiSerupa 4.0 Internasional (CC BY-NC-SA 4.0).

Buku ini boleh disebarluaskan dan diadaptasi untuk keperluan
nonkomersial dengan mencantumkan identitas penulis/penerbit serta
melisensikan karya baru di bawah ketentuan yang sama.

Kata Pengantar

Satu piksel citra satelit tidak pernah berisi satu objek tunggal. Pada petak sawah Jawa yang sempit, satu piksel Sentinel-2 berukuran 10×10 meter umumnya memuat campuran padi, air, tanah, dan gulma sekaligus. Pertanyaan mengenai jenis varietas karena itu tidak dapat dijawab dengan klasifikasi satu label, melainkan menuntut penguraian spektral linear (linear spectral unmixing, LSU) untuk mengurai proporsi penyusunnya.

Buku ini disusun dari riset terapan Laboratorium Geospasial, Departemen Teknik Geomatika ITS, di persawahan Indramayu dan Ngawi, memakai data Sentinel-2, Landsat 9, MODIS, dan WorldView-2 beresolusi 2 meter. Pembahasannya terbagi dalam enam belas bab. Bab I sampai Bab V membangun fondasi teori: kesulitan pemetaan tingkat varietas, model campuran linear, algoritme fully constrained least squares (FCLS) tervektor, mutu endmember, dan reduksi kanal. Bab VI sampai Bab IX menetapkan alur kerja: pemilihan sensor, fenologi MODIS, masker padi, hingga prosedur baku enam tahap. Bab X sampai Bab XIII menyajikan hasil beserta dokumentasi kegagalan metodologis. Bab XIV sampai Bab XVI merangkum kerangka kerja, peninjauan dua artikel terdahulu, dan inventarisasi data.

Empat dari lima varietas berhasil dipisahkan dengan akurasi pemisahan spektral 91,1 persen, sedangkan kegagalan pemisahan IR64 dan Ciherang terbukti sebagai batas fisik, bukan kelemahan algoritme. Bab XII mendokumentasikan empat pendekatan yang hanya menaikkan metrik diagnostik tanpa memperbaiki hasil, dan Bab XIII menunjukkan kelemahan metrik RMSE yang turun hampir enam kali lipat ketika akurasi turun hampir dua belas poin persen.

Buku ini dilengkapi butir kesimpulan tiap bab, lembar fakta yang dapat ditelusuri, rekomendasi bertingkat, glosarium 63 istilah dwibahasa, dan 21 rujukan pustaka. Satu batasan dinyatakan: validasi baru mencakup pemisahan spektral, belum akurasi tematik lapangan. Buku ini menjadi rujukan bagi mahasiswa, peneliti, dan praktisi penginderaan jauh pertanian dengan dasar aljabar linear dan Python.

Surabaya, Oktober, 2026
Lalu Muhamad Jaelani

DAFTAR ISI

BAB I MENGAPA PEMETAAN VARIETAS ITU SULIT.....	15
1.1 Satu piksel, banyak benda.....	15
1.2 Dari klasifikasi biner ke fraksi sub-piksel.....	16
1.3 Mengapa varietas layak diperjuangkan.....	18
1.4 Mengapa ini sulit — tiga sumber kesulitan.....	19
1.5 Ruang lingkup dan posisi buku ini.....	21
1.6 Peta jalan.....	22
1.7 Satu peringatan di awal.....	23
1.8 Cara membaca angka dalam buku ini.....	23
BAB II MODEL CAMPURAN LINEAR DAN GEOMETRI SIMPLEKS	25
2.1 Model campuran linear.....	25
2.2 Mengapa model ini masuk akal untuk sawah.....	26
2.3 Dua kendala yang masuk akal.....	27
2.4 Geometri: mengapa simpleks.....	28
2.5 Convex hull dan maknanya.....	29
2.6 Mengapa piksel di luar hull tidak punya solusi sah.....	30
2.7 Dimensi intrinsik dan rasio singular.....	32
2.8 Tiga ukuran diagnostik.....	33
2.9 Mengapa geometri ini menentukan seluruh pekerjaan.....	34
BAB III FULLY CONSTRAINED LEAST SQUARES.....	37
3.1 Dari model campuran ke satu masalah optimisasi.....	37
3.2 Empat tingkatan kendala.....	38
3.2.1 Tingkat pertama: kuadrat terkecil tanpa kendala.....	38
3.2.2 Tingkat kedua: kendala jumlah-satu saja.....	39

3.2.3 Tingkat ketiga: kendala non-negatif saja.....	39
3.2.4 Tingkat keempat: FCLS, kedua kendala sekaligus.....	40
3.2.5 Satu contoh hitung.....	41
3.3 Mengapa FCLS tidak punya bentuk tertutup.....	42
3.4 Algoritma dan kompleksitasnya.....	43
3.5 Invarian skala dan mengapa ia menentukan.....	45
3.6 Implementasi tervektor dan catatan penting.....	45
3.7 Yang perlu diingat dari bab ini.....	47
BAB IV ENDMEMBER: SUMBER, KUALITAS, DAN	
VARIABILITAS.....	49
4.1 Mata rantai yang paling lemah.....	49
4.2 Tiga jalan memperoleh endmember.....	49
4.3 Metode ekstraksi geometris: PPI dan kerabatnya.....	51
4.4 Contoh konkret: apa yang sebenarnya ditemukan PPI.....	52
4.5 Variabilitas endmember: masalah inti.....	53
4.6 Mengukur kualitas endmember.....	54
4.7 Kalibrasi lapangan dan arah lanjut.....	57
4.8 Yang perlu diingat dari bab ini.....	58
BAB V METODE REDUKSI DAN PEMETAAN BAND	
ENDMEMBER.....	59
5.1 Dua langkah yang sering dianggap satu.....	59
5.2 Mengapa pilihan ini tidak boleh diabaikan.....	60
5.3 Lima metode reduksi.....	60
5.4 Tiga metode pemetaan band.....	61
5.5 Cara pengujian dan mengapa metriknya berubah.....	62
5.6 Hasil: peringkat lima belas kombinasi.....	63

5.7 Akurasi per varietas: siapa yang paling terbantu.....	64
5.8 Mana yang lebih menentukan: reduksi atau pemetaan?.....	65
5.9 Uji silang: memutus sirkularitas.....	66
5.10 Uji ketahanan terhadap derau.....	67
5.11 Dampak pada peta.....	69
5.12 Mengapa Nearest Band unggul: hipotesis yang tidak terbukti.....	70
5.13 RMSE: sekali lagi menyesatkan.....	71
5.14 Rekomendasi dan dasar pemilihannya.....	72
5.15 Jebakan teknis.....	73
5.16 Yang perlu diingat dari bab ini.....	74
BAB VI MEMILIH SENSOR: MENGAPA SENTINEL-2, BUKAN LANDSAT.....	77
6.1 Pilihan sensor bukan soal selera.....	77
6.2 Apa yang dibutuhkan untuk memisahkan varietas.....	77
6.2.1 Mengapa klorofil menciptakan tebing red-edge.....	78
6.2.2 Struktur daun dan hamburan internal.....	79
6.2.3 Kandungan air dan wilayah inframerah gelombang pendek....	79
6.3 Tiga sensor dibandingkan.....	80
6.4 Mengapa Landsat memangkas jarak antar-varietas.....	80
6.5 Kuantifikasi: dari bilangan bulat ke reflektansi.....	81
6.6 Validasi lintas-sensor: Landsat 9 mengonfirmasi Sentinel-2.....	82
6.7 Cara kerja kanal Sentinel-2 secara teknis.....	84
6.8 Mengapa resolusi 20 meter penting untuk petak sawah Indonesia. 85	
6.8.1 Bukti terukur: apa yang sebenarnya hilang ketika piksel membesar.....	86
6.9 Memilih scene Sentinel-2: awan, SCL, dan harmonisasi baseline..	89

6.10 Membaca hasil validasi Landsat 9 lebih dalam.....	90
6.11 Alternatif sensor dan trade-off biaya-manfaat.....	92
6.12 Konsekuensi untuk pemilihan sensor.....	94
BAB VII FENOLOGI PADI DENGAN MODIS.....	97
7.1 Mengapa bab ini bukan pelengkap.....	97
7.2 Konsep dasar fenologi dari satelit.....	97
7.2.1 Siklus tumbuh padi Indonesia dan lama setiap fase.....	98
7.2.2 Mengapa dua musim tanam per tahun terjadi di Indramayu. .	100
7.3 EVI dan mengapa lebih baik daripada NDVI.....	101
7.3.1 Mengapa kejenuhan NDVI merugikan penentuan puncak.....	102
7.4 NDFI: mendeteksi genangan sebagai penanda sawah.....	102
7.4.1 Mengapa NDFI bekerja secara fisis.....	103
7.5 Algoritme PhenoRice dan pelajarannya.....	105
7.5.1 Mengapa setiap kriteria agronomis ada.....	106
7.5.2 Tapis Savitzky–Golay: mengapa jendela 7 dan orde 2.....	107
7.6 Pelaksanaan pada data Indramayu.....	108
7.6.1 Kanal DetailedQA MOD13Q1 bit per bit.....	109
7.6.2 Mengapa pencarian awal dan akhir musim dibatasi 150 hari.	110
7.7 Hasil: bukti bahwa yang terdeteksi memang sawah.....	112
7.7.1 Mengapa durasi 92 hari menjadi bukti yang kuat.....	113
7.8 Tanggal pembungaan dan jendela citra yang benar.....	114
7.8.1 Tafsiran sebaran tanggal pembungaan dan kaitannya dengan irigasi bergilir.....	115
7.9 Temuan yang mengubah arah analisis.....	116
7.10 Yang perlu diingat dari bab ini.....	118

BAB VIII MASKER PADI DAN CARA MENILAINYA DENGAN BENAR.....	121
8.1 Mengapa masker diperlukan.....	121
8.2 Menyusun masker: tiga syarat.....	121
8.2.1 Cara kerja Scene Classification Layer kelas per kelas.....	122
8.2.2 Penurunan indeks spektral dan alasan pemilihannya.....	123
8.3 Kelemahan masker yang perlu diakui.....	125
8.4 Pengaruh masker yang lebih ketat.....	126
8.5 Jebakan pertama: F1 menyesatkan pada kelas tidak seimbang.....	127
8.6 Metrik yang benar.....	128
8.7 Tafsiran hasil.....	129
8.8 Satu pembandingan yang perlu selalu disertakan.....	130
8.9 Yang perlu diingat dari bab ini.....	130
8.10 Membaca matriks kekeliruan dengan benar.....	131
8.11 Matematika MCC, kappa Cohen, dan IoU dengan contoh.....	132
8.12 Mengapa F1 gagal pada kelas tidak seimbang: contoh angka....	134
8.13 Mengapa gabungan (ATAU) lebih baik daripada irisan (DAN).136	
8.14 Menentukan ambang MCC untuk pengambilan keputusan.....	137
8.15 Keterbatasan ESA WorldCover sebagai acuan.....	138
BAB IX ALUR KERJA ENAM TAHAP.....	141
9.1 Mengapa alur kerja perlu ditetapkan.....	141
9.2 Ringkasan alur kerja.....	142
9.3 Tahap 1 — Memilih endmember.....	143
9.4 Tahap 2 — Menguji endmember sebelum memproses.....	144
9.4.1 Koreksi atmosfer: langkah yang tidak boleh dilewati.....	146
9.5 Tahap 3 — Memilih sensor.....	147

9.6 Tahap 4 — Menentukan jendela tanggal.....	148
9.7 Tahap 5 — Memisahkan padi dan non-padi.....	150
9.8 Tahap 6 — Menjalankan penguraian.....	152
9.9 Mengapa urutan ini penting.....	153
9.10 Ringkasan.....	154
9.11 Biaya waktu dan penyimpanan tiap tahap.....	155
9.12 Memeriksa data sebelum diproses.....	156
BAB X HASIL: APA YANG BISA DAN TIDAK BISA DIPETAKAN	159
10.1 Dua pertanyaan yang harus dijawab terpisah.....	159
10.2 Kemampuan mesin: akurasi pemisahan spektral.....	160
10.3 Hasil pada citra nyata.....	164
10.4 Dominasi Mekongga dan mengapa ia bukan artefak.....	166
10.5 Pola spasial: membedakan struktur nyata dari derau.....	170
10.6 Sebaran padi dan apa yang dikatakannya.....	171
10.7 Apa yang tidak dapat dipetakan.....	172
10.8 Ringkasan.....	174
BAB XI INVESTIGASI CONVEX HULL: SEBUAH STUDI KASUS	177
11.1 Sebuah angka yang tidak masuk akal.....	177
11.2 Mengapa hull kosong itu layak diselidiki.....	178
11.3 Hipotesis pertama: fase citra salah.....	179
11.4 Hipotesis kedua: endmember salah.....	181
11.5 Akar masalah: perbedaan sifat pengukuran.....	182
11.6 Mengapa penskalaan tidak menyelesaikannya.....	184
11.7 Konfirmasi lintas-sensor: Landsat 9.....	186

11.8 Pelajaran metodologis: diagnostik bukan tujuan.....	187
11.9 Apa yang akhirnya diketahui.....	189
BAB XII EMPAT PENDEKATAN YANG TERBUKTI GAGAL.....	191
12.1 Mengapa bab ini ditulis.....	191
12.2 Titik tolak: endmember apa adanya.....	192
12.3 Pendekatan pertama: penskalaan skalar $k=0,40$	193
12.4 Pendekatan kedua: penambahan kelas non-padi.....	195
12.5 Pendekatan ketiga: koreksi per kanal.....	197
12.6 Pendekatan keempat: ekstraksi piksel murni (PPI).....	199
12.7 Pola yang menghubungkan keempatnya.....	201
12.8 Yang perlu diingat dari bab ini.....	202
BAB XIII METRIK YANG MENYESATKAN.....	205
13.1 Dua angka yang berlawanan arah.....	205
13.2 Mengapa RMSE turun ketika endmember diperkecil.....	205
13.3 Mengapa cakupan hull bukan sasaran.....	208
13.4 Piksel ekstrem sebagai penanda yang andal.....	209
13.5 Fraksi dan urutan dominasi.....	210
13.6 Kerangka penilaian yang benar.....	212
13.6.1 Uji kebermaknaan: mana ukuran yang benar-benar meramalkan akurasi.....	213
13.6.2 Batas uji urutan dominasi: kapan ia sah dipakai.....	215
13.7 Yang perlu diingat dari bab ini.....	217
BAB XIV KERANGKA KERJA DAN ARAH LANJUT.....	219
14.1 Mengapa kerangka kerja disusun.....	219
14.2 Aturan penilaian hasil.....	219
14.3 Alur kerja operasional.....	220

14.4 Yang tidak perlu dicoba lagi.....	221
14.5 Arah pengembangan yang menjanjikan.....	222
14.6 Daftar periksa operasional.....	223
14.7 Rencana pengumpulan data lapangan.....	225
14.8 Rencana pengembangan perangkat lunak.....	226
14.9 Melatih asisten laboratorium baru dengan kerangka ini.....	228
14.10 Pelajaran metodologis yang berlaku umum.....	229
14.11 Nilai dari dokumentasi kegagalan.....	230
14.12 Ringkasan penutup.....	230
BAB XV MENINJAU ULANG TEMUAN SEBELUMNYA.....	233
15.1 Mengapa bab ini ada.....	233
15.2 Cara peninjauan dilakukan.....	233
15.3 Klaim artikel 2022: apa yang bertahan, apa yang gugur.....	234
15.3.1 Klaim "resolusi spasial rendah" — perlu dikoreksi.....	234
15.3.2 Klaim "spektral library terbatas" — gugur.....	235
15.3.3 Klaim "Ciherang tidak ada di piksel mana pun" — perlu tafsir ulang.....	236
15.4 Klaim artikel 2024: apa yang bertahan, apa yang gugur.....	237
15.4.1 Klaim "empat indeks lebih baik daripada dua" — cenderung gugur.....	237
15.4.2 Klaim "Otsu lebih dapat dipertanggungjawabkan" — bertahan sebagian.....	238
15.4.3 Klaim "RMSE sebagai ukuran mutu" — perlu dikoreksi....	238
15.4.4 Klaim "Landsat 8 lebih baik daripada Worldview-2" — belum dapat diputuskan.....	239
15.5 Temuan yang mengubah cara membaca kedua artikel.....	239
15.6 Yang memperkuat kedua artikel.....	240

15.7 Metode yang dianjurkan setelah peninjauan ini.....	241
15.8 Dua cara menentukan fase, dan mengapa yang satu harus ditinggalkan.....	242
15.9 Batas peninjauan ini.....	243
15.10 Catatan sumber gambar.....	245
15.11 Yang perlu diingat dari bab ini.....	245
BAB XVI SUMBER DATA, PUSTAKA, DAN PERANGKAT LUNAK	247
Rekomendasi.....	257
Glosarium.....	261
Daftar Pustaka.....	269

DAFTAR GAMBAR

Gambar 6.1. Hasil uji GSD pada satu adegan WorldView-2 Ngawi: detail spasial yang tersisa dan jarak.....	86
Gambar 7.1. Nilai genangan maksimum (NDFI). Sawah selalu memperlihatkan genangan pada awal musim.....	103
Gambar 7.2. Nilai puncak EVI per piksel, yang bertepatan dengan fase pembungaan.....	105
Gambar 7.3. Durasi musim tanam per piksel, dalam hari.....	112
Gambar 7.4. Panjang fase generatif per piksel, dalam hari.....	113
Gambar 7.5. Hari pembungaan per piksel, memperlihatkan pola musim tanam yang bergeser antar tahun.....	114
Gambar 8.1. Masker padi dari analisis fenologi MODIS pada resolusi 250 meter.....	126
Gambar 8.2. Masker fenologi MODIS setelah diproyeksikan ke grid Sentinel-2 berukuran 30 meter.....	126
Gambar 10.1. Varietas padi dominan pada setiap piksel. Panel (a) seluruh area kajian; panel (b).....	164
Gambar 10.2. Fraksi rata-rata per varietas pada seluruh piksel padi..	167
Gambar 10.3. Fraksi varietas Mekongga per piksel padi, disajikan sebagai bidang kontinu. Warna gelap.....	167
Gambar 10.4. Sebaran piksel padi. Panel (a) seluruh area kajian; panel (b) perbesaran 21 x 21 km.....	171
Gambar 15.1. Alur kerja yang dipakai artikel 2022: penentuan endmember, penentuan fase reproduktif.....	234
Gambar 15.2. Hasil penguraian spektral artikel 2022 di Indramayu. Fraksi endmember disajikan pada.....	236
Gambar 15.3. Kurva fenologi padi dari artikel 2024: indeks spektral NDVI, EVI, LSWI, dan MNDWI.....	237

1.1 Satu piksel, banyak benda

Ketika sebuah satelit memotret sawah, sensor tidak melihat padi. Yang terekam adalah cahaya matahari yang dipantulkan permukaan bumi, lalu diukur sebagai satu angka reflektansi (reflectance) untuk setiap kanal (band) spektral pada satu petak kecil di permukaan. Petak kecil itulah yang disebut piksel, dan ukurannya menentukan apa yang benar-benar terukur di dalamnya.

Sentinel-2, satelit yang menjadi tulang punggung pekerjaan ini, memiliki kanal beresolusi spasial 20 meter untuk kanal-kanal yang paling penting bagi analisis vegetasi — yakni kanal red-edge dan inframerah dekat. Satu piksel pada resolusi itu berarti 400 meter persegi. Dalam pekerjaan yang dilaporkan buku ini, citra kemudian disusun ulang pada grid kerja berukuran 30 meter, sehingga satu piksel mewakili kurang lebih 900 meter persegi. Perbedaan angka antara 400 dan 900 meter persegi ini bukan hal yang sepele, karena keduanya jauh lebih besar daripada ukuran satu rumpun padi. Satu rumpun padi di lapangan menempati ruang yang hanya sebagian kecil dari satu piksel, dan itulah inti persoalannya.

Untuk membuat gambaran itu konkret, perhatikan jarak tanam padi di sawah irigasi. Petani umumnya menanam dengan jarak sekitar 20 sampai 25 sentimeter antar rumpun, sehingga dalam satu petak berukuran 30 kali 30 meter — persis seluas satu piksel pada grid kerja kita — terdapat ribuan rumpun padi yang tersusun rapi. Di antara rumpun itu ada air yang menggenang, tanah yang membentuk pematang, dan celah-celah kecil tempat cahaya langsung mengenai permukaan air. Satu piksel menampung semua itu sekaligus, dan sensor hanya melaporkan satu angka per kanal untuk keseluruhan petak. Tidak ada cara memisahkan kembali rumpun dari genangan (inundation) setelah angkanya terekam, kecuali dengan model matematis yang mengasumsikan bentuk campurannya.

Dalam luasan satu piksel seperti itu, di sawah Indonesia, hampir selalu ada lebih dari satu benda: rumpun padi, permukaan air yang menggenang di sela-selanya, tanah pematang yang memisahkan petak, rumput di galengan, dan kadang bayangan pepohonan di tepi sawah. Nilai reflektansi yang terekam sensor adalah **rata-rata** dari semua benda itu, bukan nilai padi. Rata-rata ini bukan rata-rata aritmetika sederhana yang

dapat dipisahkan kembali dengan mudah, melainkan campuran berbobot dari seluruh spektrum penyusun yang datang bersamaan ke sensor. Sensor tidak mencatat siapa penyumbanganya; ia hanya mencatat hasil akhirnya.

Kesulitan pertama pemetaan varietas (variety) karena itu bukan soal citranya kabur, tetapi soal apa yang sebenarnya diukur. Jika kita ingin tahu varietas apa yang ditanam, sementara yang terekam adalah campuran padi, air, dan tanah, maka pertanyaan yang harus dijawab berubah bentuk. Kita tidak lagi bertanya "piksel ini padi atau bukan", tetapi "berapa bagian piksel ini yang berasal dari padi, dan berapa bagian dari air dan tanah".

Untuk memberi gambaran betapa besar persoalannya, bayangkan hasil pendataan yang menjadi dasar buku ini. Pada grid kerja 1.671×2.561 piksel, terdapat 4.276.094 piksel sah — yaitu piksel yang lolos penyaringan kualitas dan tidak tertutup awan. Dari jumlah itu, 1.994.687 piksel teridentifikasi sebagai padi melalui masker (mask) NDVI, atau sekitar 46,6 persen dari seluruh area sah. Artinya, hampir setengah dari daratan yang diamati adalah sawah. Sekitar dua juta piksel padi ini bukanlah dua juta pengukuran varietas yang bersih; setiap piksel adalah satu campuran yang harus diuraikan. Bila kita salah memahami sifat campuran ini, kesalahan akan berlipat dua juta kali.

Nilai NDVI pada piksel-piksel padi itu sendiri memberi petunjuk betapa beragamnya isi piksel yang sama-sama disebut "padi". Rata-ratanya 0,548, tetapi sebarannya lebar: persentil (percentile) ke-5 bernilai 0,366 dan persentil ke-95 bernilai 0,766. Selisih antara kedua ujung sebaran itu besar. Sebagian perbedaan itu berasal dari variasi antar varietas, tetapi sebagian besar justru berasal dari perbedaan umur tanaman, kerapatan kanopi (canopy), dan proporsi air serta tanah yang ikut terekam di dalam piksel. Inilah alasan mengapa pekerjaan ini tidak bisa berhenti pada satu nilai indeks per piksel.

1.2 Dari klasifikasi biner ke fraksi sub-piksel

Pendekatan yang paling banyak dipakai untuk pemetaan padi berhenti pada tingkat klasifikasi biner: sawah atau bukan sawah. Pendekatan ini bekerja baik ketika tujuannya adalah menghitung luas tanam. Pemerintah, misalnya, memerlukan angka luas panen untuk perencanaan produksi dan logistik pangan, dan untuk keperluan itu klasifikasi biner sudah memadai. Tetapi pendekatan ini memiliki batas

yang jelas: ia tidak dapat memberi tahu varietas apa yang ditanam, karena semua sawah diperlakukan sebagai satu kelas yang sama.

Cara berpikir biner ini memiliki akar historis yang panjang dalam penginderaan jauh. Selama beberapa dekade, citra satelit dianalisis dengan pendekatan klasifikasi per piksel, di mana setiap piksel diberi satu label dari sekumpulan kelas yang telah ditentukan. Pendekatan ini berasumsi bahwa setiap piksel cukup murni untuk diwakili oleh satu kelas. Pada citra resolusi kasar, asumsi itu sering cukup baik untuk pemetaan tutupan lahan tingkat umum. Namun begitu kita menuntut rincian yang lebih halus — seperti membedakan jenis tanaman, apalagi varietas tanaman — asumsi itu runtuh. Sebuah piksel yang setengah sawah dan setengah pemukiman tidak dapat dilabelkan sebagai salah satu dari keduanya.

Ketika keterbatasan itu disadari, muncul pendekatan yang tidak lagi memaksa satu label per piksel, melainkan menguraikan isi piksel menjadi bagian-bagian. Inilah yang disebut **spectral unmixing**, atau dalam bahasa Indonesia sering disebut penguraian spektral: prosedur yang memecah spektrum campuran sebuah piksel menjadi kumpulan spektrum penyusun, yang disebut **endmember (endmember)**, beserta bagian masing-masing, yang disebut **fraksi (fraction)** atau kelimpahan [1]. Keshava dan Mustard, dalam tinjauan klasik mereka, merangkum bidang ini sebagai upaya menjawab dua pertanyaan sekaligus: bahan apa saja yang ada di dalam sebuah piksel, dan berapa banyak masing-masing [1].

Istilahnya perlu dijelaskan sejak awal karena akan dipakai sepanjang buku ini. **Endmember** adalah spektrum acuan dari satu jenis permukaan — misalnya spektrum padi varietas Ciherang. **Fraksi** adalah bagian piksel yang berasal dari endmember tersebut, dinyatakan sebagai angka antara nol dan satu. Bila sebuah piksel memiliki fraksi Ciherang 0,7 dan fraksi air 0,3, artinya tujuh puluh persen dari piksel itu diperkirakan tertutup padi Ciherang dan tiga puluh persen air. Perhatikan bahwa fraksi tidak harus bulat dan tidak harus salah satu bernilai satu. Justru di situlah nilainya: fraksi dapat menyatakan keadaan setengah-setengah apa adanya, yang selama ini dipaksa menjadi label tunggal oleh klasifikasi biner.

Informasi yang lebih bernilai bagi perencanaan pertanian adalah varietas. Varietas menentukan umur tanam, kebutuhan air, ketahanan (robustness) terhadap hama, dan potensi hasil. Dua petak yang bersebelahan, keduanya sawah, dapat memiliki kebutuhan pengelolaan

yang sangat berbeda bila yang satu ditanami varietas berumur pendek dan yang lain varietas berumur panjang. Perbedaan umur tanam yang hanya beberapa minggu, misalnya, dapat menentukan apakah jadwal pengairan dua petak bertabrakan atau tidak, dan apakah panen dapat diatur agar tidak berbarengan. Dengan kata lain, informasi varietas adalah informasi yang mengubah keputusan, bukan sekadar rincian administratif.

Ada satu contoh konkret yang membantu melihat nilainya. Seorang penyuluh pertanian yang mendampingi sekelompok petani dalam satu blok irigasi perlu merencanakan jadwal pengairan. Bila ia hanya tahu bahwa seluruh blok itu sawah, ia tidak dapat berbuat banyak. Tetapi bila ia tahu bahwa separuh petak ditanami varietas berumur sekitar 90 hari dan separuh lainnya varietas berumur sekitar 120 hari, ia dapat menyusun jadwal yang memisahkan kebutuhan air kedua kelompok, sehingga puncak kebutuhan air tidak bertabrakan dan saluran irigasi tidak kelebihan beban pada satu waktu. Peta varietas, dalam hal ini, bukan sekadar produk ilmiah yang menarik; ia adalah masukan langsung bagi keputusan pengelolaan air yang berdampak pada hasil panen. Contoh ini juga menjelaskan mengapa fraksi lebih berguna daripada label tunggal: yang dibutuhkan bukanlah jawaban tegas "petak ini varietas X", melainkan perkiraan komposisi yang utuh, lengkap dengan tingkat ketidakpastiannya.

1.3 Mengapa varietas layak diperjuangkan

Di Indonesia, varietas padi bukan sekadar nama dagang. Sejak era Revolusi Hijau, pemuliaan tanaman padi telah menghasilkan rangkaian varietas yang dirilis secara resmi untuk menggantikan varietas lokal dengan hasil yang lebih tinggi dan umur yang lebih pendek. IR64 dikembangkan oleh International Rice Research Institute dan menjadi salah satu varietas paling luas ditanam pada masanya; Ciherang dirilis oleh lembaga pemuliaan nasional dan bertahan lama sebagai varietas unggulan; Inpari32 merupakan bagian dari rangkaian varietas Inpari (Inbrida Padi Irigasi) yang dirilis oleh kementerian pertanian; dan Mekongga menjadi salah satu varietas yang banyak ditanam di sentra produksi seperti Indramayu. Rincian tanggal dan nomor rilis masing-masing varietas [perlu verifikasi (verification)] bila akan dipakai dalam publikasi resmi, tetapi yang penting untuk buku ini adalah kenyataan bahwa varietas-varietas itu berdampak di lapangan pada musim (season) yang sama.

Kenyataan berdampingan itulah yang menimbulkan kebutuhan praktis. Sebuah dinas pertanian yang ingin memperkirakan produksi tidak cukup mengetahui berapa hektare sawah yang ditanami; ia perlu mengetahui varietas apa yang ditanam, karena potensi hasil, umur panen, dan kerentanannya terhadap hama berbeda antar varietas. Sebuah perusahaan yang menyediakan benih perlu mengetahui varietas mana yang mendominasi suatu wilayah agar rantai pasok benihnya tepat. Sebuah lembaga yang memantau ketahanan pangan perlu mendeteksi pergeseran komposisi varietas dari musim ke musim, karena pergeseran itu dapat menjadi tanda awal perubahan perilaku petani. Semua kebutuhan ini menuntut peta varietas, bukan sekadar peta sawah.

Untuk mendapat informasi itu, kita memerlukan pendekatan yang tidak lagi memberi satu label per piksel, tetapi menguraikan isi piksel menjadi bagian-bagian. Inilah yang disebut spectral unmixing yang telah diperkenalkan di atas. Namun sebagaimana akan terlihat sepanjang buku ini, menguraikan piksel menjadi fraksi jauh lebih sulit daripada memberi label, dan sebagian besar kesulitan itu tidak berasal dari algoritme yang kita pakai, melainkan dari sifat data itu sendiri.

1.4 Mengapa ini sulit — tiga sumber kesulitan

Pekerjaan yang dilaporkan dalam buku ini menghadapi tiga sumber kesulitan yang perlu dibedakan sejak awal, karena masing-masing menuntut penanganan yang berbeda.

Kesulitan pertama bersifat fisik. Sensor mengukur campuran. Tidak ada cara menghindari ini pada resolusi yang tersedia. Yang dapat dilakukan hanyalah menguraikan campuran itu dengan benar, dan menerima bahwa hasilnya adalah perkiraan, bukan pengukuran langsung. Kesulitan fisik ini bahkan meninggalkan jejak yang dapat diukur. Sebagaimana akan dibahas rinci pada Bab 11, hanya **0,009 persen** piksel padi — yaitu 177 dari 1.994.687 piksel — yang nilai inframerah dekatnya mencapai nilai terendah dari spektrum endmember, yaitu 0,5927. Persentil ke-99 nilai inframerah dekat citra padi hanya 0,4444, dan bahkan rata-rata piksel di atas persentil ke-99 itu masih 0,4730, masih di bawah endmember tergelap. Artinya, hampir tidak ada piksel citra yang sedekat apa pun dengan spektrum padi murni. Ini bukan tanda sensor rusak atau endmember salah; ini adalah wajah kuantitatif dari kesulitan fisik yang sama: piksel selalu memuat campuran.

Kesulitan kedua bersifat spektral. Varietas padi yang berbeda tidak selalu berbeda secara spektral. Beberapa varietas memiliki kurva reflektansi yang hampir identik pada kanal-kanal yang tersedia di Sentinel-2. Ketika dua varietas memiliki jarak spektral (spectral distance) yang sangat kecil, tidak ada algoritme yang dapat memisahkannya secara andal — bukan karena algoritmanya lemah, tetapi karena informasinya memang tidak ada di dalam data. Dalam pekerjaan ini, pasangan Ciherang–IR64 memiliki jarak spektral 0,1222, terdekat dari seluruh pasangan varietas. Akibatnya, pada pengujian dengan derau (noise) 0,010, akurasi pemisahan IR64 hanya 59,7 persen, dan 28,9 persen piksel IR64 justru disebut Ciherang. Angka-angka ini akan dibahas panjang pada Bab 10, tetapi sudah dapat dikatakan di sini bahwa ini adalah batas fisik, bukan cacat perangkat lunak. Sebagaimana dinyatakan dalam tinjauan mengenai variabilitas endmember, pemisahan spektral selalu dibatasi oleh seberapa berbeda objek yang ingin dipisahkan, dan oleh seberapa besar variasi yang tidak diinginkan ikut terekam [9].

Kesulitan ketiga bersifat metodologis. Banyak pilihan dalam rantai pengolahan memengaruhi hasil dengan cara yang tidak selalu jelas, dan beberapa di antaranya justru tampak memperbaiki hasil sementara sebenarnya merusaknya. Buku ini menghabiskan dua bab terakhir untuk membahas kelompok kesulitan ketiga ini, karena di situlah pelajaran paling mahal dari pekerjaan ini berada. Contoh yang paling tajam: sebuah ukuran galat dapat turun dari 179,4 persen menjadi 31,7 persen — tampak seperti perbaikan hampir enam kali lipat — sementara akurasi pemisahan varietas justru merosot dari 91,1 persen menjadi 79,5 persen. Dua angka itu bergerak berlawanan arah, dan siapa pun yang hanya melihat angka pertama akan menyimpulkan hal yang salah.

Ketiga sumber kesulitan ini saling terkait, tetapi tidak boleh dicampur. Kesulitan fisik menuntut penerimaan dan pelaporan yang terbuka. Kesulitan spektral menuntut pengakuan akan batas dan pemilihan sensor serta jendela waktu yang tepat. Kesulitan metodologis menuntut kehati-hatian dalam menilai hasil dan keberanian untuk menolak perbaikan yang tampak manis tetapi menyesatkan. Buku ini disusun mengikuti ketiga garis itu.

1.5 Ruang lingkup dan posisi buku ini

Buku ini adalah bahan ajar internal Laboratorium Geospasial, Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember. Isinya bukan teori umum yang dapat dibaca di buku teks mana pun, melainkan catatan dari pekerjaan yang benar-benar dilakukan: pemetaan varietas padi di dataran pantai utara Jawa Barat, di Kabupaten Indramayu dan sekitarnya, menggunakan citra Sentinel-2 dan endmember spektral dari basis data Speclib yang dikelola laboratorium [15]. Rincian sumber data, pustaka, dan perangkat lunak yang dipakai dicatat pada Bab 16.

Area kajian membentang dari 107,8498 sampai 108,5400 derajat bujur timur, dan dari 6,6802 sampai 6,2299 derajat lintang selatan, atau sekitar 76,6 kali 49,8 kilometer. Luasan ini dipilih karena merupakan salah satu sentra produksi padi terpenting di Pulau Jawa, dengan hamparan sawah irigasi yang luas dan pola tanam yang relatif seragam sepanjang tahun. Keragaman varietas di dalamnya cukup untuk menguji metode pemisahan, sementara hamparan yang luas memberi jumlah piksel yang memadai untuk pengujian statistik. Dengan 1.994.687 piksel padi, area ini menyediakan lebih dari cukup bahan untuk menguji apakah metode yang dipakai benar-benar bekerja pada skala nyata, bukan hanya pada contoh kecil yang dipilih agar berhasil.

Ada dua hal yang membedakan buku ini dari laporan biasa. **Pertama**, buku ini mencatat bukan hanya apa yang berhasil, tetapi juga apa yang gagal — dan kegagalan itu dibahas dengan angka yang sama telitinya dengan keberhasilan. Dalam banyak laporan teknis, kegagalan dihilangkan atau disamarkan, sehingga pembaca berikutnya mengulang jalan yang sama. Buku ini mengambil sikap sebaliknya: empat pendekatan yang terbukti gagal dilaporkan lengkap dengan angkanya, supaya tidak ada yang mengulang pekerjaan yang sama. **Kedua**, buku ini menjelaskan konsep dasarnya, sehingga pembaca yang baru bergabung dengan laboratorium dapat mengikuti tanpa harus membaca literatur lain lebih dahulu.

Sitasi literatur tetap disertakan di tempat-tempat yang memerlukannya, terutama untuk konsep yang bukan berasal dari pekerjaan ini. Pembaca yang ingin mendalami teori di balik suatu metode dapat menelusuri rujukannya. Namun perlu ditegaskan bahwa angka-angka dalam buku ini — akurasi, jarak spektral, fraksi, cakupan hull (hull coverage) — bukan kutipan dari literatur, melainkan hasil pengukuran

laboratorium ini pada data yang disebutkan. Pemisahan yang tegas antara keduanya adalah bagian dari disiplin yang ingin ditanamkan buku ini.

1.6 Peta jalan

Buku ini disusun dalam empat bagian.

Bagian I menjelaskan dasar teori. Bab 2 membahas model campuran linear dan geometri yang mendasarinya — terutama konsep convex hull, yang akan menjadi poros sebagian besar diskusi di bagian akhir buku. Bab 3 membahas algoritme yang dipakai, Fully Constrained Least Squares, termasuk satu sifatnya yang ternyata sangat menentukan. Bab 4 membahas endmember: dari mana asalnya, bagaimana kualitasnya dinilai, dan mengapa variabilitasnya menjadi masalah inti.

Bagian II membahas data dan metode. Bab 6 membandingkan sensor, khususnya mengapa Sentinel-2 dipilih dan mengapa Landsat tidak memadai untuk pemisahan varietas. Bab 7 membahas fenologi (phenology) padi dengan MODIS, dan bagaimana fenologi dipakai untuk menentukan kapan citra seharusnya diambil. Bab 8 membahas penyusunan masker padi dan — ini bagian yang mudah salah — bagaimana menilai kualitas masker itu dengan metrik yang benar.

Bagian III membahas pelaksanaan. Bab 9 menyusun alur kerja enam tahap. Bab 10 melaporkan hasil: apa yang dapat dipetakan dan apa yang tidak. Bab 11 adalah studi kasus investigasi convex hull — kisah tentang gejala yang tampak serius, dua hipotesis yang diuji dan ditolak, dan akar masalah yang ternyata berbeda dari dugaan semula.

Bagian IV membahas kegagalan dan pelajaran. Bab 12 melaporkan empat pendekatan perbaikan yang seluruhnya terbukti gagal. Bab 13 membahas mengapa metrik yang biasa dipakai justru menyesatkan dalam kasus ini. Bab 14 menyusun kerangka kerja sebagai acuan operasional dan menutup dengan arah pengembangan berikutnya.

Pembaca yang hanya ingin tahu kesimpulan praktisnya dapat membaca Bab 10, 11, dan 13 lebih dahulu. Namun pembaca yang ingin memahami mengapa kesimpulan itu berbunyi demikian perlu melewati Bagian I, karena hampir semua kejutan dalam pekerjaan ini berakar pada geometri yang diperkenalkan di Bab 2.

1.7 Satu peringatan di awal

Sebelum masuk ke teori, satu peringatan yang akan berulang beberapa kali dalam buku ini: **angka yang terlihat bagus belum tentu berarti hasil yang baik**. Dalam pekerjaan ini, ditemukan bahwa sebuah ukuran galat dapat turun hampir enam kali lipat sementara akurasi pemisahan varietas justru turun hampir dua belas poin persen. Ukuran seperti itu tidak boleh dipakai untuk menilai apakah sebuah pengolahan berhasil.

Peringatan ini disampaikan di awal bukan untuk menakut-nakuti, tetapi supaya pembaca membaca angka-angka di bab-bab berikutnya dengan sikap yang tepat: memeriksa apa yang diukur, bukan hanya seberapa bagus angkanya. Sebuah angka galat yang kecil hanya berarti model cocok dengan data yang dimasukkan; ia tidak dengan sendirinya berarti model itu benar. Sebuah akurasi pemisahan yang tinggi hanya berarti kelas yang diuji dapat dipisahkan pada kondisi uji tertentu; ia tidak dengan sendirinya berarti peta yang dihasilkan akurat di lapangan. Kedua hal itu berbeda, dan membedakannya adalah salah satu tujuan utama buku ini.

1.8 Cara membaca angka dalam buku ini

Agar pembaca dapat mengikuti dengan aman, ada empat jenis angka yang dibedakan tegas sepanjang buku ini. **Pertama, angka terukur dari pekerjaan ini** — akurasi pemisahan, jarak spektral, fraksi varietas, cakupan hull, dan sejenisnya. Semua angka ini berasal dari lembar fakta laboratorium dan dapat ditelusuri ke berkas hasilnya. **Kedua, angka dari literatur** — yang dirujuk dengan sitasi bernomor dan bukan hasil pengukuran kita. **Ketiga, teori dan konsep** — yang dijelaskan untuk memberi kerangka, dan ditandai dengan sitasi bila berasal dari sumber tertentu. **Keempat, tafsiran dan refleksi** — penilaian penulis mengenai mengapa sesuatu terjadi atau apa artinya bagi praktik, yang harus dibaca sebagai pendapat yang beralasan, bukan sebagai fakta terukur.

Pembaca juga akan menemukan sejumlah angka yang secara sengaja **tidak** dipakai. Lembar fakta laboratorium memuat daftar angka yang telah terbukti salah — misalnya akurasi masker yang dihitung pada grid yang tidak sejajar, atau jumlah piksel padi yang dihitung ganda di tepi mosaik. Angka-angka seperti itu disebut dalam buku ini hanya ketika memang perlu

menjelaskan sebuah koreksi, dan selalu disertai alasan mengapa angka itu salah. Kebiasaan menyimpan dan menyebut angka yang salah, beserta sebab kesalahannya, adalah bagian dari disiplin laboratorium yang ingin diwariskan buku ini kepada pembaca berikutnya.

Satu contoh nyata dari disiplin itu adalah koreksi jumlah piksel padi. Pada satu tahap pekerjaan, jumlah piksel padi tercatat 2.000.708, tetapi setelah diperiksa ternyata piksel tepi terhitung dua kali saat menyusun mosaik, sehingga angka yang benar adalah 1.994.687. Selisihnya hanya sekitar enam ribu piksel — kurang dari sepertiga persen — dan secara praktis tidak mengubah kesimpulan besar. Namun angka yang salah tetap dicatat sebagai salah dan tidak dipakai lagi, karena dalam pekerjaan yang bersandar pada akurasi pecahan persen, kebiasaan membiarkan angka yang tidak dapat dipertanggungjawabkan akan cepat menular. Prinsipnya sederhana: setiap angka yang dilaporkan harus dapat ditelusuri ke sumbernya, dan angka yang tidak dapat ditelusuri tidak layak dipakai, sekecil apa pun dampaknya.

Dengan kerangka itu, pembaca siap masuk ke inti teori. Bab berikutnya memperkenalkan model matematis yang menjadi dasar seluruh pekerjaan ini — model campuran linear — beserta geometri yang mengikutinya, karena di dalam geometri itulah sebagian besar kesulitan praktis yang akan kita hadapi sebenarnya bersembunyi.

BAB II MODEL CAMPURAN LINEAR DAN GEOMETRI SIMPLEKS

2.1 Model campuran linear

Dasar seluruh pembahasan dalam buku ini adalah satu persamaan sederhana. Model campuran linear menganggap bahwa spektrum yang terekam pada sebuah piksel adalah jumlah berbobot dari spektrum benda-benda penyusunnya:

$$\mathbf{x} = f_1\mathbf{e}_1 + f_2\mathbf{e}_2 + \dots + f_n\mathbf{e}_n + \boldsymbol{\varepsilon}$$

Di sini $\mathbf{x}$ adalah spektrum piksel yang terukur — deretan angka reflektansi pada setiap kanal. $\mathbf{e}_1$ **sampai** $\mathbf{e}_n$ adalah spektrum endmember, yaitu spektrum acuan dari masing-masing benda penyusun. f_1 **sampai** f_n adalah fraksi masing-masing endmember, dan $\boldsymbol{\varepsilon}$ adalah sisa yang tidak dapat dijelaskan oleh model, biasanya dianggap sebagai derau [1].

Model ini disebut *linear* karena hubungannya berbentuk penjumlahan berbobot. Ini berbeda dari model *nonlinear*, yang diperlukan ketika cahaya mengalami pemantulan berkali-kali di dalam satu objek sebelum kembali ke sensor. Untuk permukaan seperti tanah dan vegetasi yang jarang, di mana cahaya umumnya hanya memantul satu kali, model linear merupakan pendekatan yang memadai dan telah menjadi dasar sebagian besar pekerjaan penguraian spektral (spectral unmixing) [1].

Gagasan bahwa spektrum campuran dapat diuraikan sebagai jumlah berbobot komponennya bukan gagasan baru. Akarnya dapat ditelusuri pada perkembangan awal spektroskopi pantulan dan penginderaan jauh hiperspektral pada dekade 1980-an dan 1990-an, ketika instrumen pertama yang merekam ratusan kanal sempit memungkinkan pengamatan bahwa setiap bahan memiliki "sidik jari" spektral yang khas. Ketika beberapa bahan berada dalam satu piksel, sidik jari itu saling tumpang tindih (overlap), dan muncul pertanyaan apakah tumpang tindih itu dapat dipisahkan kembali. Model campuran linear adalah jawaban paling sederhana dan paling banyak dipakai untuk pertanyaan itu. Keshava dan Mustard, dalam tinjauan yang menjadi rujukan standar bidang ini, menempatkan model linear sebagai titik tolak dan membahas berbagai pengembangan serta keterbatasannya [1].

Perlu dicatat bahwa model ini adalah **asumsi**, bukan kenyataan. Ia menganggap bahwa setiap benda menyumbang spektrumnya secara

proporsional terhadap luas yang ditempatinya, tanpa saling mengganggu. Untuk sawah dengan kanopi yang rapat, asumsi ini mulai melemah, karena cahaya yang memantul dari tanah di bawah kanopi harus melewati dedaunan terlebih dahulu, dan cahaya yang sudah melewati dedaunan tidak lagi sekadar menambahkan kontribusi tanah secara linear. Namun untuk keperluan praktis, dan khususnya pada skala resolusi yang kita hadapi, model linear tetap menjadi pilihan yang masuk akal dan paling banyak dipakai.

Ada satu konsekuensi penting dari pemilihan model linear yang perlu ditegaskan sejak awal. Karena model ini mengasumsikan bahwa setiap benda menyumbang secara proporsional terhadap luas, maka fraksi yang dihasilkan dapat ditafsirkan sebagai proporsi luas — dengan kata lain, sebagai persentase piksel yang tertutup benda tersebut. Inilah yang membuat penguraian spektral berguna untuk pemetaan: hasilnya bukan sekadar daftar bahan yang hadir, melainkan perkiraan berapa banyak masing-masing bahan hadir. Namun tafsiran proporsi luas itu hanya sah bila kendala-kendala yang dibahas berikutnya diterapkan. Tanpa kendala itu, fraksi hanyalah koefisien matematis tanpa makna fisik.

2.2 Mengapa model ini masuk akal untuk sawah

Model campuran linear bukan sekadar kemudahan matematis; ia masuk akal untuk kasus yang kita hadapi, yaitu sawah. Sebuah piksel sawah pada dasarnya adalah mozaik benda-benda yang berdekatan secara horizontal: kanopi padi, genangan air di antara rumpun, tanah pematang, dan celah antar rumpun. Cahaya matahari jatuh dari atas, memantul sekali dari masing-masing benda, lalu masuk ke sensor. Dalam susunan seperti ini, tidak banyak pemantulan berkali-kali antar benda, sehingga penjumlahan berbobot cukup menggambarkan apa yang terjadi.

Bandingkan dengan hutan lebat atau kanopi yang sangat tertutup, di mana cahaya masuk ke dalam kanopi, memantul berkali-kali antar daun, dan sebagian keluar lagi setelah mengalami banyak interaksi. Pada kasus seperti itu, kontribusi tanah di bawah kanopi tidak lagi proporsional terhadap luasnya, karena cahaya yang mencapai tanah sudah berkurang oleh daun di atasnya, dan cahaya yang kembali dari tanah berkurang lagi saat keluar. Model linear menjadi kurang tepat, dan diperlukan model nonlinear yang jauh lebih rumit. Sawah yang diamati dalam pekerjaan ini, dengan kanopi yang tidak sepenuhnya menutup dan genangan air yang

terlihat di antara rumpun, berada di wilayah di mana model linear masih wajar dipakai.

Kendati demikian, perlu diakui bahwa pada fase pertumbuhan tertentu — khususnya ketika kanopi padi sudah rapat dan menutup penuh — asumsi linear mulai terganggu. Ini salah satu alasan mengapa penentuan jendela waktu citra menjadi penting, dan mengapa Bab 7 membahas fenologi secara khusus. Memilih citra pada fase yang tepat bukan hanya soal memperoleh perbedaan varietas yang paling jelas, tetapi juga soal menjaga agar asumsi dasar model tetap wajar.

Perlu dicatat pula bahwa model campuran linear mengabaikan interaksi antar benda di dalam piksel. Secara fisik, cahaya yang memantul dari permukaan air dapat memantul lagi ke dedaunan sebelum masuk ke sensor, dan interaksi semacam itu tidak tertangkap oleh penjumlahan berbobot sederhana. Namun pengabaian ini disengaja, karena ia membuat masalah menjadi dapat diselesaikan. Model yang memasukkan interaksi antar benda akan jauh lebih rumit, memerlukan parameter tambahan yang tidak dapat diperoleh dari citra, dan sering kali tidak memberikan perbaikan yang sepadan untuk keperluan praktis. Keshava dan Mustard menegaskan bahwa model linear telah terbukti memadai untuk sebagian besar aplikasi penginderaan jauh, dan bahwa penyimpangan darinya biasanya hanya muncul pada kanopi yang sangat tertutup atau pada kondisi geometri pengamatan yang ekstrem [1]. Dengan mengenali kapan asumsi itu mulai melemah, kita dapat memilih data yang tepat, bukan sekadar menjalankan algoritme pada data apa pun yang tersedia.

2.3 Dua kendala yang masuk akal

Fraksi adalah bagian dari piksel. Karena itu ada dua hal yang secara logis harus benar mengenai fraksi, dan keduanya dinyatakan sebagai kendala pada model [2].

Kendala non-negatif (non-negativity constraint). Tidak ada fraksi yang boleh bernilai negatif. Fraksi sebesar $-0,2$ untuk varietas Ciherang tidak memiliki arti: tidak mungkin ada "minus dua puluh persen" dari sebuah piksel yang tertutup padi. Kendala ini dituliskan sebagai $f_i \geq 0$ untuk semua i .

Kendala jumlah-satu. Seluruh fraksi harus berjumlah tepat satu, karena seluruh bagian piksel harus terjelaskan. Kendala ini dituliskan sebagai $\sum f_i = 1$.

Kedua kendala ini tampak sepele, tetapi memiliki konsekuensi besar. Tanpa kendala non-negatif, solusi kuadrat terkecil biasa dapat menghasilkan fraksi negatif, dan solusi seperti itu hanya berguna untuk mendeteksi keberadaan suatu bahan, bukan untuk mengukur berapa banyak [2]. Fraksi negatif, dalam bahasa geometris, berarti model "mengurangkan" kontribusi sebuah bahan agar cocok dengan data — sesuatu yang secara fisik tidak mungkin, tetapi secara matematis diizinkan bila kendala tidak dipasang. Tanpa kendala jumlah-satu, skala hasilnya menjadi tidak terikat, dan hasilnya tidak dapat ditafsirkan sebagai proporsi luas.

Kendala jumlah-satu juga memiliki makna geometris yang dalam. Ia memaksa titik solusi untuk selalu berada pada satu bidang tertentu di ruang spektral — bidang di mana seluruh koordinat barisentrik berjumlah satu. Bidang inilah yang nantinya menjadi "lantai" tempat simpleks (simplex) berada. Sebagaimana akan terlihat pada Bab 3, kendala ini juga yang membuat hasil penguraian menjadi invarian terhadap penskalaan endmember — sebuah sifat yang ternyata menjelaskan sebagian besar hasil mengejutkan dalam pekerjaan ini.

Metode yang menerapkan kedua kendala sekaligus disebut **Fully Constrained Least Squares**, disingkat FCLS. Metode inilah yang dipakai sepanjang buku ini, dan dibahas secara rinci pada Bab 3.

2.4 Geometri: mengapa simpleks

Di sinilah geometri masuk, dan di sinilah sebagian besar kesulitan praktis dalam pekerjaan ini berasal. Perlu satu langkah berpikir untuk melihatnya.

Bayangkan penyederhanaan paling sederhana: hanya ada dua endmember, misalnya padi dan air, dan hanya dua kanal, misalnya merah dan inframerah dekat. Setiap piksel dapat digambarkan sebagai satu titik pada bidang dengan sumbu merah dan sumbu inframerah dekat. Endmember padi adalah satu titik, endmember air adalah titik lain.

Sekarang, bagaimana bentuk himpunan semua campuran yang mungkin? Campuran 100% padi adalah titik padi itu sendiri. Campuran

100% air adalah titik air. Campuran 50-50 adalah titik tengah di antara keduanya. Campuran 30% padi dan 70% air adalah titik yang berada sepertiga jalan dari air menuju padi. Seluruh campuran yang mungkin adalah **ruas garis** yang menghubungkan kedua titik itu.

Tambahkan endmember ketiga, misalnya tanah. Sekarang himpunannya menjadi **segitiga** yang ketiga sudutnya adalah ketiga endmember. Campuran dua bahan yang diletakkan di sisi segitiga; campuran tiga bahan yang diletakkan di dalam segitiga. Tambahkan yang keempat: himpunannya menjadi bangun berdimensi tiga, yaitu tetrahedron. Secara umum, dengan n endmember, himpunan semua campuran yang mungkin adalah bangun berdimensi $(n-1)$ yang sudut-sudutnya adalah endmember itu sendiri.

Bangun inilah yang disebut **simpleks**. Dalam dua dimensi ia berupa segitiga, dalam tiga dimensi berupa tetrahedron, dan seterusnya ke dimensi yang lebih tinggi [3].

Ada satu hal yang membuat simpleks istimewa untuk masalah kita: setiap titik di dalamnya memiliki **koordinat barisentrik** yang unik. Koordinat barisentrik adalah bobot yang harus diberikan pada setiap sudut agar titik itu dapat dinyatakan sebagai kombinasi sudut-sudutnya. Dalam segitiga, misalnya, setiap titik di dalam segitiga memiliki satu set bobot unik untuk ketiga sudutnya. Bobot-bobot itulah yang menjadi fraksi kita. Jadi, menguraikan spektrum piksel menjadi fraksi setara dengan mengubah koordinat piksel dari sistem kanal spektral ke sistem koordinat barisentrik terhadap simpleks endmember. Boardman merumuskan seluruh masalah penguraian spektral dalam bahasa geometri seperti ini, dan itulah kerangka yang dipakai buku ini [3].

Penyederhanaan dua dimensi di atas juga mengungkap mengapa jumlah endmember tidak bisa sembarang. Dalam ruang dua dimensi, paling banyak ada tiga sudut yang saling bebas — selebihnya akan terletak di dalam segitiga dan bukan lagi menjadi sudut yang sesungguhnya. Prinsip ini akan kita perluas menjadi gagasan dimensi intrinsik pada bagian akhir bab ini.

2.5 Convex hull dan maknanya

Simpleks selalu berada di dalam **convex hull** dari titik-titik endmember. Istilah convex hull, atau selubung cembung, merujuk pada

bangun terkecil yang membungkus seluruh titik yang diberikan. Secara lebih tepat, convex hull dari sekumpulan titik adalah himpunan semua kombinasi linear dari titik-titik itu yang bobotnya non-negatif dan berjumlah satu. Bandingkan definisi ini dengan kendala yang kita pasang pada fraksi: keduanya identik. Convex hull dari endmember karena itu adalah himpunan semua campuran yang mungkin secara fisik, karena himpunan itu dibatasi persis oleh kendala non-negatif dan jumlah-satu.

Dalam kasus kita, karena seluruh endmember adalah sudut-sudut simpleks, convex hull-nya berimpit dengan simpleks itu sendiri. Konsekuensinya bersifat matematis dan tidak dapat ditawar: **setiap piksel yang benar-benar merupakan campuran dari endmember-endmember itu pasti berada di dalam convex hull**. Ini bukan aturan yang dibuat manusia, melainkan konsekuensi langsung dari definisi convex hull [3].

Konsekuensi ini memberikan sebuah uji yang sangat kuat. Jika kita memiliki citra dan seperangkat endmember, kita dapat memeriksa berapa persen piksel citra yang jatuh di dalam convex hull endmember. Bila hampir semua piksel berada di dalamnya, maka endmember itu cukup mewakili isi citra. Bila hampir tidak ada piksel yang berada di dalamnya, maka ada sesuatu yang mendasar tidak cocok antara endmember dan citra. Ukuran ini disebut **cakupan hull**, dan ia akan menjadi salah satu ukuran diagnostik utama dalam buku ini.

Namun perlu ditegaskan sejak sekarang: cakupan hull adalah **diagnostik**, bukan sasaran. Ia memberi tahu kita apakah ada ketidakcocokan, tetapi ia tidak memberi tahu apa penyebabnya, dan ia tidak boleh dijadikan tujuan yang harus dimaksimalkan. Pada Bab 12 dan 12 akan terlihat bahwa memaksimalkan cakupan hull justru dapat memperburuk hasil, dan bahwa perbedaan antara "menggunakan ukuran sebagai alat diagnosis" dan "menggunakan ukuran sebagai sasaran" adalah salah satu pelajaran terpenting dari pekerjaan ini.

2.6 Mengapa piksel di luar hull tidak punya solusi sah

Bagian yang paling penting dari geometri ini adalah sisi sebaliknya: **piksel yang berada di luar convex hull tidak memiliki solusi fraksi yang sah**. Tidak ada kombinasi fraksi yang memenuhi kedua kendala sekaligus yang dapat menghasilkan spektrum seperti itu. Algoritme apa

pun, secanggih apa pun, tidak akan menemukan jawaban yang benar, karena jawabannya memang tidak ada di dalam ruang solusi.

Perlu dipahami mengapa hal ini bukan sekadar keterbatasan algoritme. Bayangkan sebuah titik yang berada di luar segitiga pada bidang. Titik itu tidak dapat dinyatakan sebagai campuran berbobot dari ketiga sudut segitiga dengan bobot non-negatif yang berjumlah satu. Tidak ada cara menulis titik itu sebagai $f_1 e_1 + f_2 e_2 + f_3 e_3$ dengan $f_i \geq 0$ dan $\sum f_i = 1$. Ini bukan soal algoritme yang belum cukup pintar; ini soal aritmetika dasar. Sebuah titik di luar segitiga secara geometris berada di luar jangkauan kombinasi yang diizinkan.

Yang terjadi ketika algoritme menghadapi piksel seperti itu adalah solusinya "terdorong ke batas". Karena tidak ada titik di dalam yang cocok, algoritme memilih titik terdekat pada batas simpleks. Akibatnya fraksi yang dihasilkan menjadi ekstrem — satu kelas mendapat nilai mendekati satu, kelas-kelas lain mendekati nol. Solusi seperti ini kadang disebut solusi sudut, dan secara praktis tidak bermakna sebagai perkiraan proporsi luas.

Ada satu jenis piksel yang biasanya berada di luar hull, dan penting untuk dikenali sejak awal: piksel yang mengandung bahan yang **tidak ada** di dalam daftar endmember. Bila endmember kita hanya berisi lima varietas padi, tetapi citra memuat pula air, tanah, dan bangunan, maka piksel-piksel air, tanah, dan bangunan itu berada di luar hull padi. Inilah salah satu alasan mengapa masker padi (Bab 8) menjadi langkah penting: kita menjalankan penguraian hanya pada piksel yang sudah diperkirakan sebagai padi, supaya bahan lain tidak mengotori hasil. Namun, seperti akan terlihat, menambahkan kelas non-padi ke dalam daftar endmember justru membawa masalahnya sendiri, dan pendekatan itu terbukti gagal dalam pengujian kami.

Boardman, dalam makalahnya mengenai otomatisasi penguraian spektral, merumuskan seluruh masalah ini sebagai masalah geometri [3]. Menentukan jumlah endmember setara dengan menentukan dimensi intrinsik sebaran data. Menentukan spektrum endmember setara dengan mencari simpleks yang paling sesuai membungkus sebaran data. Dan menentukan fraksi setiap piksel setara dengan mengubah koordinat piksel ke koordinat barisentrik terhadap simpleks tersebut.

2.7 Dimensi intrinsik dan rasio singular

Dua konsep geometris terakhir yang perlu diperkenalkan di sini berkaitan erat: dimensi intrinsik dan rasio singular (singular-value ratio). Keduanya menentukan seberapa sulit pemisahan yang kita hadapi, jauh sebelum satu piksel pun diuraikan.

Sebuah citra dengan sembilan kanal secara teknis berada di ruang sembilan dimensi. Tetapi data citra biasanya tidak benar-benar menyebar ke seluruh sembilan dimensi itu. Sebagian besar variasi biasanya terkumpul pada beberapa arah saja, karena kanal-kanal yang berdekatan mengukur hal yang serupa. Jumlah arah bebas yang benar-benar dipakai oleh data disebut **dimensi intrinsik**. Menentukan dimensi intrinsik penting karena ia memberi tahu berapa banyak endmember yang masuk akal untuk dicari. Sebagaimana dirumuskan Boardman, bila data secara intrinsik berdimensi n , maka jumlah endmember yang dapat dipisahkan adalah $n+1$ [3]. Mencari lebih banyak endmember daripada yang didukung data berarti mencari perbedaan yang tidak ada di dalam data — dan hasilnya adalah endmember yang sebenarnya hanya variasi dari endmember lain, bukan kelas yang benar-benar berbeda. Pada Bab 10 dan 11 akan terlihat bagaimana pelanggaran prinsip ini menjelaskan kegagalan salah satu pendekatan yang diuji.

Ukuran yang lebih operasional untuk menilai geometri endmember adalah **rasio singular**. Matriks endmember, yang setiap kolomnya adalah spektrum satu endmember, memiliki nilai-nilai singular (singular value) yang menggambarkan panjang sumbu-sumbu utama simpleks yang dibentuknya. Rasio antara nilai singular terbesar dan terkecil adalah ukuran seberapa "gepeng" simpleks itu. Simpleks yang sangat gepeng berarti beberapa endmember hampir segaris, sehingga arah pemisah di antara mereka sangat tipis dan mudah tenggelam oleh derau. Rasio yang besar menandakan pemisahan yang tidak stabil.

Dalam pekerjaan ini, rasio singular dari matriks endmember pada sembilan kanal Sentinel-2 adalah **410,8**. Ini angka yang sangat besar, dan ia memberitahu kita sejak awal bahwa geometri pemisahan varietas padi memang rawan. Sebagai pembanding, ketika endmember yang sama direduksi ke empat kanal yang setara dengan kanal Landsat, rasio singularnya menjadi 79,4. Kedua angka ini menegaskan satu hal yang akan berulang: ruang pemisahan yang tersedia sempit, dan sebagian besar arah di

dalamnya nyaris tidak terpakai. Menariknya, sebagaimana akan terlihat pada Bab 12, upaya memperbaiki geometri dengan mengubah skala endmember tidak mengubah rasio singular secara berarti — dari 410,8 menjadi 411,8 — dan memang tidak memperbaiki akurasi. Rasio singular, seperti cakupan hull, lebih berguna sebagai diagnostik daripada sebagai sasaran.

2.8 Tiga ukuran diagnostik

Dari kerangka geometris di atas, muncul tiga ukuran yang berguna untuk menilai endmember sebelum menjalankan penguraian. Ketiganya akan dipakai berulang dalam buku ini.

Cakupan hull. Berapa persen piksel yang berada di dalam convex hull endmember. Angka ini mengukur apakah endmember yang dipilih memang mencakup objek yang ada di citra. Nilai nol berarti tidak ada satu piksel pun yang dapat dijelaskan oleh endmember tersebut. Dalam pekerjaan ini, cakupan hull pada bidang merah–inframerah dekat, red-edge1–inframerah dekat, dan red-edge2–inframerah dekat seluruhnya bernilai 0,0 persen, dan rata-rata hanya 2,4 dari 9 kanal yang nilainya berada di dalam rentang endmember. Ini temuan yang mengejutkan dan akan dibahas panjang pada Bab 11.

Rasio singular. Perbandingan antara nilai singular terbesar dan terkecil dari matriks endmember, sebagaimana dijelaskan pada bagian sebelumnya. Angka ini mengukur seberapa gepeng simpleksnya, dan karenanya seberapa rapuh arah pemisahannya.

Jarak antar endmember. Ukuran sederhana seberapa berbeda dua spektrum, dihitung sebagai jarak Euclidean antara dua vektor spektrum. Bila dua endmember berjarak sangat kecil, tidak ada metode yang dapat memisahkannya secara andal, karena perbedaan di antara keduanya lebih kecil daripada derau citra. Dalam pekerjaan ini, pasangan Ciherang–IR64 berjarak 0,1222 — terdekat dari semua pasangan — dan pasangan itu pula yang paling sulit dipisahkan. Sebagai pembanding, pasangan yang jauh seperti IR64–Inpari32_WBC berjarak 0,9672, hampir delapan kali lebih besar, dan pasangan itu memang jauh lebih mudah dipisahkan.

Ketiga ukuran ini akan muncul berkali-kali, dan pada Bab 11 akan terlihat bagaimana salah satu di antaranya justru menyesatkan bila dijadikan sasaran alih-alih diagnostik. Perlu ditekankan bahwa ketiganya

harus dibaca bersama-sama. Cakupan hull yang rendah dengan jarak antar endmember yang besar menunjukkan satu masalah; cakupan hull yang rendah dengan jarak antar endmember yang kecil menunjukkan masalah yang berbeda. Tidak ada satu angka tunggal yang cukup untuk menilai kesiapan endmember.

Sebagai gambaran konkret, perhatikan bagaimana ketiga ukuran itu bekerja bersama pada data kita. Jarak antar endmember memberi tahu kita bahwa pasangan Ciherang–IR64 hampir berimpit, dengan jarak 0,1222, sementara pasangan IR64–Inpari32_WBC terpisah jauh, dengan jarak 0,9672. Rasio singular 410,8 memberi tahu kita bahwa secara keseluruhan simpleksnya sangat gepeng, sehingga arah pemisah rata-rata memang tipis. Cakupan hull 0,0 persen pada bidang merah–inframerah dekat memberi tahu kita bahwa citra tidak berada di dalam simpleks itu sama sekali. Tiga angka ini, dibaca bersama-sama, sudah memberi diagnosis yang cukup jelas sebelum satu piksel pun diuraikan: sebagian kelas mungkin masih dapat dipisahkan berkat jaraknya yang besar, tetapi kelas yang berdekatan akan sulit, dan masalah cakupan hull menuntut penjelasan tersendiri. Ketika nanti penguraian benar-benar dijalankan, hasilnya persis seperti yang diramalkan oleh ketiga angka itu — sebuah contoh bahwa diagnostik geometris yang dilakukan lebih dahulu dapat menghemat banyak pekerjaan yang sia-sia.

2.9 Mengapa geometri ini menentukan seluruh pekerjaan

Bila pembaca hanya membawa satu gagasan dari bab ini ke bab-bab berikutnya, gagasan itu adalah: **penguraian spektral adalah masalah geometri, dan batas kemampuan penguraian ditentukan oleh geometri itu, bukan oleh algoritme.** Algoritme terbaik sekalipun tidak dapat memisahkan dua endmember yang praktis berimpit, dan tidak dapat memberi solusi sah bagi piksel yang berada di luar hull. Algoritme hanya bekerja sebaik geometri yang disediakan.

Kerangka geometris ini menjelaskan hampir semua kejutan dalam pekerjaan ini. Ia menjelaskan mengapa IR64 sulit dipisahkan dari Ciherang — karena jarak spektralnya terpendek. Ia menjelaskan mengapa cakupan hull bernilai nol — karena piksel citra berada jauh di luar simpleks endmember. Ia menjelaskan mengapa memaksimalkan cakupan hull justru memperburuk hasil — karena cakupan hull hanyalah gejala, bukan sebab. Dan ia menjelaskan mengapa penskalaan endmember tidak berguna —

karena kendala jumlah-satu membuat fraksi invarian terhadap penskalaan seragam.

Bab berikutnya memperkenalkan algoritme yang dipakai, Fully Constrained Least Squares, beserta satu sifatnya yang ternyata sangat menentukan. Setelah itu, Bab 4 membahas endmember dari sisi sumber dan kualitasnya. Baru setelah dasar teori itu lengkap, kita masuk ke data dan metode pada Bagian II, dan akhirnya ke pelaksanaan serta pelajaran pada Bagian III dan IV.

Sebagai penutup bab ini, ada baiknya pembaca memegang satu pertanyaan sederhana yang akan terus muncul: berapa banyak informasi tentang varietas yang sebenarnya tersedia di dalam citra, dan berapa banyak yang hanya kita harapkan ada? Seluruh sisa buku ini dapat dibaca sebagai usaha menjawab pertanyaan itu secara terbuka. Geometri yang diperkenalkan di atas memberi kita cara mengukur seberapa besar ruang yang benar-benar tersedia untuk pemisahan, dan dengan demikian melindungi kita dari dua kesalahan yang sama-sama berbahaya: mengklaim keberhasilan yang tidak didukung data, dan menyerah pada batas yang sebenarnya masih dapat ditembus. Menemukan garis yang tepat di antara keduanya — bukan dengan perasaan, tetapi dengan ukuran — adalah inti dari pekerjaan yang dilaporkan buku ini.

3.1 Dari model campuran ke satu masalah optimisasi

Bab sebelumnya berhenti pada satu kesimpulan yang perlu dijadikan titik tolak bab ini. Penguraian spektral (spectral unmixing) bukan sekadar urusan mencocokkan kurva, melainkan urusan geometri: setiap piksel adalah satu titik di ruang spektral, endmember (endmember) adalah titik-titik sudut, dan seluruh campuran yang mungkin adalah bangun yang direntang oleh titik-titik sudut itu. Mencari fraksi (fraction) berarti mencari tahu di mana posisi piksel di dalam bangun tersebut, dinyatakan dalam koordinat terhadap sudut-sudutnya.

Begitu masalahnya dilihat seperti itu, pekerjaan kita berubah bentuk menjadi satu masalah optimisasi yang harus dipecahkan untuk **setiap piksel**. Kita mencari vektor fraksi yang paling baik menjelaskan spektrum piksel, tetapi tidak semua jawaban boleh diterima. Hanya jawaban yang memenuhi aturan main fisika — bagian tidak boleh negatif dan seluruhnya harus berjumlah satu — yang dapat ditafsirkan sebagai proporsi luas. Aturan main itulah yang kita sebut kendala, dan bab ini membahas bagaimana kendala tersebut diubah menjadi persamaan dan pertidaksamaan yang dapat dihitung.

Satu hal yang perlu ditegaskan sejak awal: metode yang dibahas di sini bekerja **per piksel**, tetapi hasilnya dilaporkan sebagai satu himpunan fraksi untuk seluruh citra. Pemahaman ini penting karena akan menjelaskan mengapa biaya komputasi metode ini berbeda jauh dari metode klasifikasi biasa. Klasifikasi memberi satu label kepada satu piksel dengan satu keputusan sederhana. Penguraian spektral menyelesaikan satu masalah optimisasi berdimensi kecil untuk setiap piksel, dan pada citra yang kita hadapi jumlah pikselnya mendekati dua juta. Angka itu akan muncul kembali di bagian akhir bab, ketika kita membahas mengapa implementasi menjadi soal yang tidak sepele.

Perbedaan sifat ini juga membawa konsekuensi tafsir yang penting. Pada klasifikasi, jawaban untuk satu piksel bersifat tunggal dan pasti: piksel itu masuk kelas A, bukan kelas B. Pada penguraian spektral, jawaban untuk satu piksel berbentuk sebaran: sekian bagian kelas A, sekian bagian kelas B, dan seterusnya. Karena itu, penilaian mutu hasil pun tidak dapat memakai ukuran yang sama. Pertanyaan "berapa persen piksel yang

diklasifikasikan benar" harus digantikan oleh pertanyaan yang lebih rinci, misalnya "seberapa sering kelas yang benar memperoleh fraksi terbesar", dan — yang lebih penting — "seberapa besar galat fraksinya". Sepanjang buku ini, ukuran pertama yang dipakai adalah matriks kekeliruan (confusion matrix) piksel murni (pure pixel), sedangkan ukuran kedua masih menunggu validasi (validation) lapangan. Keduanya akan dibedakan dengan tegas di Bab 10.

3.2 Empat tingkatan kendala

Kendala yang kita bicarakan ada dua: non-negatif ($f_i \geq 0$) dan jumlah-satu ($\sum f_i = 1$). Keduanya dapat diterapkan atau tidak diterapkan secara terpisah, sehingga menghasilkan empat tingkatan masalah yang berbeda. Tingkatan-tingkatan ini bukan sekadar variasi teknis; masing-masing menghasilkan solusi dengan sifat dan tafsir yang berbeda, dan literatur secara eksplisit membedakannya [2,12]. Memahami perbedaan ini penting karena banyak kesalahan praktis berasal dari memakai solusi satu tingkatan untuk keperluan tingkatan yang lain.

3.2.1 Tingkat pertama: kuadrat terkecil tanpa kendala

Bentuk paling dasar adalah kuadrat terkecil biasa, yaitu mencari fraksi yang meminimalkan jumlah kuadrat selisih antara spektrum piksel dan spektrum model:

$$\text{minimize } \|x - Ef\|^2$$

dengan x adalah vektor spektrum piksel, E adalah matriks yang kolom-kolomnya adalah spektrum endmember, dan f adalah vektor fraksi yang dicari. Masalah ini punya penyelesaian bentuk tertutup (closed form) yang klasik. Dengan menurunkan fungsi tujuan terhadap f dan menyamakannya dengan nol, kita memperoleh persamaan normal:

$$E^T E f = E^T x$$

sehingga, selama matriks $E^T E$ dapat dibalik,

$$f = (E^T E)^{-1} E^T x$$

Bentuk ini indah karena sederhana dan cepat, tetapi mengandung satu cacat yang membuatnya tidak dapat dipakai untuk kuantifikasi. Tidak ada satu pun kendala yang menjaganya. Nilai fraksi yang dihasilkan dapat berupa angka negatif, dan jumlahnya tidak dijamin satu. Solusi seperti ini — disebut *unconstrained least squares* — memang berguna untuk **mendeteksi keberadaan** suatu bahan, karena nilai positif yang besar menandakan bahan itu ada, tetapi ia **tidak dapat dipakai untuk**

mengukur berapa banyak bahan itu ada [2]. Perbedaan antara "mendeteksi" dan "mengukur" inilah yang menjadi tema berulang sepanjang buku ini.

3.2.2 Tingkat kedua: kendala jumlah-satu saja

Tingkat berikutnya menerapkan kendala jumlah-satu saja. Masalahnya menjadi:

$$\text{minimize } \|x - Ef\|^2 \quad \text{dengan kendala } \sum f_i = 1$$

Kendala ini menarik karena berbentuk **satu persamaan linear**, bukan sekumpulan pertidaksamaan. Persamaan linear mudah ditangani, dan memang masalah ini masih memiliki penyelesaian bentuk tertutup. Kita dapat menurunkannya dengan pengali Lagrange. Definisikan fungsi Lagrange:

$$L(f, \lambda) = \|x - Ef\|^2 + \lambda(\sum f_i - 1)$$

Turunan terhadap f menghasilkan syarat stasioner:

$$-2E^T x + 2E^T E f + \lambda \cdot 1 = 0$$

dengan **1** adalah vektor berisi angka satu semua. Dari sini:

$$f = (E^T E)^{-1} (E^T x - (\lambda/2) \cdot 1)$$

Nilai pengali λ ditentukan dengan memasukkan syarat jumlah-satu.

Jika kita menuliskan

$$a = 1^T (E^T E)^{-1} E^T x \quad \text{dan} \quad b = 1^T (E^T E)^{-1} 1$$

maka syarat $1^T f = 1$ memberi $a - (\lambda/2) \cdot b = 1$, sehingga $\lambda/2 = (a - 1)/b$. Dengan demikian fraksi hasilnya dapat dituliskan seluruhnya dalam besaran yang sudah diketahui. Jadi tingkatan ini punya bentuk tertutup, sama seperti tingkatan pertama.

Tetapi keindahan itu tidak cukup. Karena kendala non-negatif (non-negativity constraint) tidak diterapkan, solusinya **dapat berisi fraksi negatif**. Pada contoh yang akan kita lihat di Subbab 3.2.5, nilai negatif itu muncul justru pada kasus yang paling penting — yaitu piksel yang lebih gelap daripada seluruh endmember. Dengan kata lain, kendala jumlah-satu saja tidak menyelamatkan kita dari solusi yang tak bermakna.

3.2.3 Tingkat ketiga: kendala non-negatif saja

Tingkat ketiga membalik situasinya: yang diterapkan justru kendala non-negatif, sedangkan jumlah-satu dilepas. Masalahnya:

$$\text{minimize } \|x - Ef\|^2 \quad \text{dengan kendala } f_i \geq 0 \text{ untuk semua } i$$

Inilah yang dalam literatur disebut *non-negative least squares*, disingkat NNLS. Perubahan kecil pada rumusan membawa konsekuensi besar pada sifat matematisnya. Solusinya **tidak lagi punya bentuk tertutup**. Alasannya dapat dipahami melalui kondisi optimalitas Karush–Kuhn–Tucker (KKT). Pada titik optimum, berlaku:

$$f_i \geq 0, \quad (E^T E f - E^T x)_i \geq 0, \quad f_i \cdot (E^T E f - E^T x)_i = 0$$

Syarat terakhir inilah yang menjadi kunci: untuk setiap indeks i , **salah satu** dari dua hal harus berlaku — entah fraksi f_i bernilai nol, entah turunannya bernilai nol. Himpunan indeks yang fraksinya nol disebut **himpunan aktif** (active set). Yang membuat masalah ini tidak punya bentuk tertutup adalah kenyataan bahwa himpunan aktif itu **bergantung pada data**: kita tidak dapat mengetahui lebih dahulu indeks mana yang akan aktif sebelum menyelesaikan masalahnya. Setiap kombinasi himpunan aktif menghasilkan sistem persamaan yang berbeda, dan jumlah kombinasinya bertambah secara eksponensial terhadap jumlah endmember.

3.2.4 Tingkat keempat: FCLS, kedua kendala sekaligus

Baru ketika **kedua** kendala diterapkan sekaligus, kita memperoleh solusi yang dapat ditafsirkan sebagai proporsi luas:

$$\text{minimize } \|x - Ef\|^2 \quad \text{dengan kendala } \sum f_i = 1 \text{ dan } f_i \geq 0$$

Inilah **Fully Constrained Least Squares**, disingkat FCLS [2,12]. Kendala jumlah-satu memberi arti kuantitatif pada fraksi — jumlah bagian sama dengan keseluruhan — sedangkan kendala non-negatif menjaga agar tidak ada bagian yang bernilai negatif. Keduanya harus hadir bersamaan. Tanpa yang pertama, fraksi hanya bermakna relatif; tanpa yang kedua, fraksi bisa tak bermakna.

Secara geometris, himpunan fraksi yang memenuhi kedua kendala adalah **simpleks (simplex)** — segitiga pada kasus tiga endmember, tetrahedron pada kasus empat endmember, dan seterusnya. Karena itu FCLS sesungguhnya adalah masalah **memproyeksikan** piksel ke simpleks tersebut, lalu membaca koordinat barisentrik titik hasil proyeksi. Tafsiran geometris ini akan kembali muncul berkali-kali, karena ia menjelaskan mengapa solusi FCLS dapat "terdorong ke sudut" ketika piksel berada jauh di luar bangun.

3.2.5 Satu contoh hitung

Agar perbedaan keempat tingkatan tidak tinggal sebagai rumus, marilah kita hitung satu contoh sederhana yang seluruh angkanya diambil dari lembar fakta. Kita pakai **satu kanal (band)** saja — kanal inframerah dekat (B8) — dan **dua endmember** yang mewakili rentang terlebar di antara kelima varietas (variety), yaitu Inpari32 dengan NIR terendah 0,5927 dan Mekongga dengan NIR 0,7160. Rentang di antara keduanya hanya 0,1233.

Dengan hanya satu kanal, penyelesaiannya menjadi sangat sederhana. Kuadrat terkecil tanpa kendala memberi dua fraksi yang sama besar, $f = x \cdot (e_1 + e_2) / (e_1^2 + e_2^2)$. Penyelesaian jumlah-satu memberi $f_1 = (e_2 - x) / (e_2 - e_1)$ dan $f_2 = 1 - f_1$. FCLS menambahkan pemotongan pada rentang nol sampai satu. Hasilnya untuk beberapa nilai x yang juga diambil dari lembar fakta disajikan pada tabel berikut.

x (NIR piksel)	Keterangan x	Tanpa kendala f_1	Σ tanpa kendala	Jumlah -satu f_1	Jumlah -satu f_2	FCLS f_1	FCLS f_2
0,2884	p50 piksel padi	0,4369	0,8737	3,468	-2,468	1,000	0,000
0,4444	p99 piksel padi	0,6732	1,3463	2,203	-1,203	1,000	0,000
0,4730	rata-rata p99 ke atas	0,7165	1,4330	1,971	-0,971	1,000	0,000
0,5927	endmember Inpari32	0,8978	1,7956	1,000	0,000	1,000	0,000
0,6800	di dalam hull	1,0301	2,0601	0,292	0,708	0,292	0,708
0,7160	endmember Mekongga	1,0846	2,1692	0,000	1,000	0,000	1,000

Tabel ini memperlihatkan tiga hal yang penting sekaligus, dan ketiganya akan terpakai di bab-bab berikutnya.

Pertama, solusi tanpa kendala tidak pernah menjumlah satu. Jumlahnya berkisar dari 0,8737 hingga 2,1692 pada contoh ini. Artinya fraksi tanpa kendala bukan proporsi luas; ia hanya ukuran keberadaan relatif. Ini bukti angka atas apa yang tadi dikatakan secara konsep.

Kedua, solusi jumlah-satu saja menghasilkan fraksi negatif untuk seluruh piksel yang lebih gelap daripada endmember tergelap. Begitu x turun di bawah 0,5927, nilai f_1 melampaui satu dan f_2 menjadi negatif. Ini bukan keanehan contoh, melainkan sifat umum: kendala jumlah-satu memaksa bobot untuk berjumlah satu, dan ketika piksel berada di luar rentang, bobot itu terpaksa "keluar" dari rentang yang sah. Perhatikan bahwa p50 dan bahkan p99 piksel pada seluruhnya berada di bawah endmember tergelap.

Ketiga, dan yang paling menentukan, FCLS memotong seluruh kasus $x < 0,5927$ menjadi solusi sudut $f = (1, 0)$. Piksel yang lebih gelap daripada seluruh endmember tidak punya solusi sah di dalam simpleks, sehingga algoritme menempelkannya pada sudut terdekat. Dalam pekerjaan nyata, **hampir semua piksel pada mengalami hal ini** — hanya 177 dari 1.994.687 piksel pada (0,009%) yang mencapai NIR endmember tergelap. Inilah akar dari fenomena yang akan menjadi poros Bab 11: cakupan convex hull yang nol bukan kesalahan hitung, melainkan konsekuensi dari perbedaan sifat pengukuran. Contoh sederhana di atas menunjukkan mekanismenya dengan telanjang.

3.3 Mengapa FCLS tidak punya bentuk tertutup

Sekarang kita dapat memahami mengapa tingkatan keempat kehilangan bentuk tertutup yang dimiliki tingkatan pertama dan kedua. Yang menghilangkannya bukan kendala jumlah-satu — kendala itu tetap berupa persamaan linear yang mudah ditangani. Yang menghilangkannya adalah **kendala non-negatif**, karena ia berupa sekumpulan pertidaksamaan.

Bayangkan pencarian titik terendah pada sebuah permukaan. Bila titik terendah itu berada di bagian dalam daerah yang diperbolehkan, maka kendala pertidaksamaan tidak aktif, dan solusinya sama dengan solusi tanpa kendala. Tetapi bila titik terendah itu berada di luar daerah yang

diperbolehkan, solusinya akan menempel pada batas. Pertanyaannya: batas yang mana? Jawabannya bergantung pada bentuk permukaannya. Pada satu piksel, solusinya menempel pada satu rusuk simpleks; pada piksel lain, pada satu sudut; pada piksel ketiga, tetap di bagian dalam. Karena ada begitu banyak kemungkinan wajah simpleks yang dapat ditemplei, dan wajah mana yang terpilih bergantung pada posisi piksel, tidak ada satu rumus tunggal yang dapat merangkum seluruh kasus.

Inilah sebabnya Heinz dan Chang menyatakan bahwa tidak ada bentuk tertutup untuk FCLS, dan mengembangkan algoritme iteratif untuk memperoleh solusi optimalnya [2]. Perlu dicatat bahwa ketiadaan bentuk tertutup ini bukan kelemahan yang bisa "diperbaiki" dengan trik aljabar; ia melekat pada masalahnya. Sebagaimana ditunjukkan kemudian oleh Chang dan Li dalam rumusan analitisnya, yang dapat diperoleh adalah penyelesaian analitis untuk **kondisi aktif tertentu** — misalnya ketika diketahui lebih dahulu fraksi mana saja yang bernilai nol — bukan satu rumus tunggal untuk semua kasus [11]. Praktisnya, ketiadaan bentuk tertutup berarti setiap piksel menuntut penyelesaian masalah optimisasi tersendiri, dan dari sinilah persoalan komputasi muncul.

3.4 Algoritma dan kompleksitasnya

Bagaimana algoritme FCLS sebenarnya bekerja? Gagasan Heinz dan Chang bertumpu pada dua langkah [2], yang dirumuskan secara lengkap pada makalah FCLS yang pertama [12]. Langkah pertama menangani kendala jumlah-satu **secara eksak** dengan mengubahnya menjadi bagian dari sistem persamaan. Caranya adalah membentuk sistem teraugmentasi: matriks endmember ditambah satu baris berisi angka satu, dan vektor piksel ditambah satu unsur berisi angka satu. Sistem yang diperbesar ini, bila diselesaikan dengan kuadrat terkecil, otomatis memenuhi syarat jumlah-satu.

Marilah kita tuliskan bentuk teraugmentasi itu secara eksplisit, karena penurunannya menyingkap mengapa langkah ini bekerja. Definisikan matriks **U** yang dibentuk dengan menumpuk matriks endmember **E** di atas sebuah vektor baris berisi angka satu, dan vektor **y** yang dibentuk dengan menumpuk vektor piksel **x** di atas satu angka. Yakni:

$$U = \begin{bmatrix} E \\ 1^T \end{bmatrix} \quad y = \begin{bmatrix} x \\ 1 \end{bmatrix}$$

Sekarang selesaikan kuadrat terkecil minimize $\|y - Uf\|^2$. Karena suku terakhir dari selisih ini adalah $1 - 1^T f$, fungsi tujuan tersebut dapat diuraikan menjadi dua bagian:

$$\|y - Uf\|^2 = \|x - Ef\|^2 + (1 - \sum f_i)^2$$

Suku kedua inilah kuncinya. Ia bernilai nol tepat ketika $\sum f_i = 1$, dan bernilai positif ketika jumlah fraksi menyimpang dari satu. Artinya, dengan memaksakan kuadrat terkecil pada sistem teraugmentasi, kita **sekaligus** memaksakan kendala jumlah-satu: solusi yang tidak menjumlah satu akan dihukum oleh suku kedua, dan karena tujuannya meminimalkan, solusi optimal pasti menjumlah satu. Dengan satu langkah aljabar ini, sebuah kendala kesamaan yang tadinya harus ditangani terpisah telah diserap menjadi bagian dari fungsi tujuan, tanpa menambah kerumitan bentuk. Inilah sebabnya langkah pertama dapat dikerjakan dengan operasi matriks biasa, dan bukan secara iteratif.

Perlu dicatat bahwa penyelesaian langsung sistem teraugmentasi ini **belum** menjamin non-negatif. Ia hanya menjamin jumlah-satu. Karena itu langkah kedua masih diperlukan untuk menegakkan kendala pertidaksamaan.

Langkah kedua menangani kendala non-negatif dengan prosedur NNLS. Karena sistem teraugmentasi itu sudah membawa kendala jumlah-satu di dalamnya, yang tersisa hanyalah memastikan tidak ada fraksi negatif. Prosedur NNLS bekerja dengan himpunan aktif: ia mulai dari tebakan, memeriksa syarat KKT, memasukkan indeks yang melanggar ke himpunan aktif, dan mengulang sampai semua syarat terpenuhi. Proses ini dijamin berhenti dalam jumlah langkah yang terbatas, dan solusinya terbukti optimal [2,11].

Yang perlu dipahami dari sisi praktik adalah **kompleksitasnya**. Setiap piksel memerlukan penyelesaian satu masalah NNLS yang kecil, dan masalah kecil itu sendiri memerlukan beberapa iterasi. Jumlah iterasi bergantung pada berapa banyak fraksi yang aktif (bernilai nol), yang berbeda-beda antarpiksel. Akibatnya biaya total tidak dapat dituliskan sebagai satu rumus sederhana yang tumbuh linier; ia bergantung pada data. Untuk citra berukuran sedang, biaya itu masih tertahankan. Tetapi begitu jumlah piksel membengkak menjadi jutaan, biaya per piksel yang tampak kecil berlipat menjadi beban menit, dan inilah yang terjadi pada pekerjaan ini.

Satu alternatif yang sering dipakai untuk menghindari NNLS penuh adalah **memecahkan sistem teraugmentasi dengan kuadrat terkecil biasa, lalu memotong nilai negatif menjadi nol dan menormalisasi ulang agar berjumlah satu**. Prosedur "potong dan normalisasi" ini jauh lebih cepat karena hanya melibatkan operasi matriks sekali jalan, tanpa iterasi. Tetapi ia **bukan FCLS sejati**. Ia hanya mendekati kendala non-negatif, dan pada piksel-piksel tertentu pendekatannya jauh dari benar. Konsekuensi praktis dari kekurangan ini akan diukur secara langsung pada Subbab 3.6.

3.5 Invarian skala dan mengapa ia menentukan

Ada satu sifat FCLS yang sudah diperkenalkan pada bab sebelumnya dan telah dibuktikan secara matematis, sehingga di sini cukup dirujuk tanpa diulang. Sifat itu adalah **invarian skala (scale invariance)**: karena kendala jumlah-satu mengikat fraksi untuk berjumlah satu, apa yang menentukan solusi adalah **bentuk relatif** spektrum — pola perbandingan antar kanal — bukan tingkat kecerahannya secara mutlak.

Konsekuensi praktisnya tunggal dan tegas: **segala upaya memperbaiki hasil dengan menyesuaikan skala endmember tidak akan berhasil**. Yang dapat berubah hanyalah angka galat yang dilaporkan, bukan isi fraksinya. Sifat ini akan terpakai berkali-kali. Pada Bab 12 dan Bab 13 akan terlihat bagaimana sifat ini menjelaskan mengapa tiga dari empat pendekatan perbaikan yang diuji gagal, dan mengapa angka RMSE yang tampak membaik justru menyesatkan. Perlu diingat pula bahwa sifat ini berlaku untuk **penskalaan seragam**; bila yang diubah adalah bentuk spektrumnya — misalnya mengalikan setiap kanal dengan angka yang berbeda — maka sifat ini tidak lagi berlaku, dan fraksi memang akan berubah. Perbedaan itu menjadi inti pembahasan koreksi per kanal di Bab 12.

3.6 Implementasi tervektor dan catatan penting

Ketika jumlah piksel mendekati dua juta, penyelesaian per piksel menjadi mahal. Karena itu, dalam pekerjaan ini penyelesaian per piksel dibandingkan dengan implementasi alternatif yang memanfaatkan operasi matriks tervektor. Hasil pengukurannya sangat tegas.

Implementasi	Waktu	Catatan
FCLS per piksel	276–360 detik	untuk satu scene

Implementasi	Waktu	Catatan
(pysptools)		
FCLS tervektor NumPy	0,12 detik	2.653× lebih cepat
Unmixing 2 juta piksel	~14 detik	endmember apa adanya

Percepatan lebih dari dua ribu kali ini menggoda untuk langsung diadopsi. Tetapi percepatan bukan segalanya; yang harus dibuktikan adalah apakah hasilnya tetap setara. Pengujian pada data yang sama menunjukkan bahwa pada sebagian besar piksel selisihnya memang sangat kecil: rata-rata 0,00083 dan pada persentil (percentile) ke-95 sebesar 0,00237. Jumlah piksel yang kelas dominannya berbeda hanya sekitar 0,02 persen.

Namun ada satu catatan penting yang harus disampaikan, dan catatan ini penting justru karena mudah diabaikan. Implementasi tervektor yang diuji memakai prosedur **potong dan normalisasi**, yang — sebagaimana dijelaskan di Subbab 3.4 — **bukan** FCLS sejati. Akibatnya, pada sebagian kecil piksel, selisihnya dapat mencapai **1,0 penuh**. Artinya pada piksel-piksel itu fraksinya berbeda total dari solusi sejati: satu implementasi mengatakan fraksi terpusat pada satu kelas, yang lain pada kelas yang sama sekali berbeda. Bahwa selisih rata-rata kecil tidak menyelamatkan keadaan, karena kesalahan justru terkonsentrasi pada piksel-piksel yang paling sulit — dan piksel-piksel itulah yang biasanya paling menarik perhatian.

Karena itu, implementasi cepat semacam ini **tidak boleh dipakai untuk publikasi ilmiah** tanpa digantikan oleh penyelesaian non-negatif yang sebenarnya, seperti algoritma NNLS dari pustaka ilmiah standar. Pelajaran praktisnya: percepatan besar memang mungkin, tetapi klaim bahwa sebuah implementasi cepat "setara" dengan implementasi acuan harus **dibuktikan dengan pengukuran, bukan diasumsikan**. Selisih maksimum yang mencapai 1,0 adalah bukti bahwa klaim kesetaraan tidak berlaku umum, sekalipun rata-ratanya tampak mulus.

Ada satu jebakan penalaran yang perlu disingkirkan di sini, karena mudah menjebak pembaca yang teliti. Ketika dua implementasi dibandingkan, wajar bila kita menghitung selisih rata-rata dan menyimpulkan keduanya setara bila angkanya kecil. Namun selisih rata-rata dan selisih maksimum mengukur dua hal yang berbeda. Selisih rata-rata mengukur perilaku **khas**, sedangkan selisih maksimum mengukur perilaku **terburuk**. Pada keperluan kuantifikasi, yang menentukan bukan

perilaku khas, melainkan perilaku terburuk: sebuah peta fraksi yang benar pada 99,98% piksel tetapi salah total pada 0,02% piksel tetap mengandung kesalahan yang tidak dapat diterima pada piksel-piksel itu. Karena itu, setiap kali sebuah implementasi cepat diusulkan sebagai pengganti, pertanyaan yang harus diajukan bukan "berapa selisih rata-ratanya", melainkan "berapa selisih maksimumnya, dan pada piksel seperti apa selisih itu terjadi". Pertanyaan kedua inilah yang paling sering tidak diajukan, dan justru yang paling menentukan.

3.7 Yang perlu diingat dari bab ini

Tiga hal dari bab ini akan terus dipakai sepanjang buku.

Pertama, ada empat tingkatan kendala, dan hanya FCLS — yang menerapkan kendala non-negatif dan jumlah-satu sekaligus — yang hasilnya dapat ditafsirkan sebagai proporsi luas. Tanpa kendala, solusinya hanya dapat mendeteksi keberadaan bahan; dengan satu kendala saja, solusinya tetap cacat. Contoh hitung pada Subbab 3.2.5 memperlihatkan cacat itu secara angka.

Kedua, FCLS tidak punya bentuk tertutup karena kendala non-negatif berupa pertidaksamaan, dan wajah simpleks tempat solusi menempel bergantung pada data. Ketidakadaan bentuk tertutup ini melekat pada masalahnya, bukan kelemahan yang bisa diakali. Invarian skala adalah sifat yang menentukan: fraksi tidak berubah oleh penskalaan seragam, hanya angka galatnya yang berubah.

Ketiga, implementasi cepat harus diuji kesetaraannya, bukan diasumsikan. Selisih maksimum yang besar pada sebagian kecil piksel adalah tanda bahwa pendekatan yang lebih sederhana tidak dapat dipakai untuk keperluan kuantifikasi.

Keempat, sifat invarian skala menjelaskan mengapa fraksi tidak berubah ketika endmember diskalakan, tetapi angka galatnya berubah. Karena itu pemilihan perlakuan endmember tidak boleh didasarkan pada nilai galat semata; ia harus didasarkan pada pengujian yang mengukur seberapa baik kelas-kelas benar-benar terpisahkan, seperti matriks kekeliruan yang dibahas pada Bab 10.

Kelima, dua implementasi FCLS yang menghasilkan solusi sama secara matematis tetap dapat berbeda pada piksel tertentu. Perbedaan itu

bukan bukti bahwa salah satunya salah, melainkan tanda bahwa masalahnya memiliki beberapa wajah simpleks yang dapat menerima solusi yang sama-sama sah. Untuk keperluan pelaporan, perbedaan seperti itu perlu dinyatakan secara terbuka, bukan disamarkan dengan pembulatan.

BAB IV ENDMEMBER: SUMBER, KUALITAS, DAN VARIABILITAS

4.1 Mata rantai yang paling lemah

Seluruh mutu hasil penguraian spektral bertumpu pada satu hal yang sering dianggap remeh: mutu endmember. Algoritme FCLS yang dibahas pada Bab 3 sudah terbukti benar sampai presisi mesin ketika diuji pada data sintetis dengan jawaban yang diketahui. Artinya, bila hasil penguraian melenceng, penyebabnya hampir pasti bukan algoritmanya. Penyebabnya adalah spektrum acuan yang kita berikan kepadanya.

Pernyataan ini bukan kesimpulan yang kami susun sendiri, melainkan sejalan dengan apa yang dinyatakan Boardman: penentuan endmember adalah mata rantai terlemah dalam rantai penguraian, karena kesahihan hasil sangat bergantung pada spektrum acuan yang disediakan pengguna [3]. Bab ini membahas mata rantai itu secara menyeluruh: dari mana endmember berasal, bagaimana kualitasnya diukur, dan mengapa variabilitasnya — sifat bahwa satu benda tidak memiliki satu spektrum tunggal — menjadi masalah inti yang menentukan batas kemampuan seluruh pekerjaan.

Perlu ditegaskan sejak awal bahwa pembahasan ini bukan pelengkap. Bab 3 menunjukkan bahwa FCLS hanya dapat menghasilkan solusi yang bermakna bila endmember yang disediakan benar-benar mewakili isi citra. Bila tidak, algoritme tidak gagal secara dramatis; ia justru akan memberi jawaban yang tampak mulus tetapi salah. Karena itu, kemampuan menilai endmember sebelum menjalankannya adalah keterampilan yang menentukan, bukan sekadar kehati-hatian.

4.2 Tiga jalan memperoleh endmember

Ada tiga jalan memperoleh endmember, dan masing-masing membawa konsekuensi yang berbeda terhadap skala dan kesahihan. Perbedaan ini bukan perbedaan cara, melainkan perbedaan **sifat pengukuran**, dan justru perbedaan sifat itulah yang akan menjelaskan kegagalan yang paling sulit dipahami dalam pekerjaan ini.

Jalan pertama: pustaka spektral. Endmember diambil dari basis data hasil pengukuran spektorradiometer di lapangan atau di laboratorium. Spektrum ini diukur pada objek yang relatif murni — misalnya kanopi

(canopy) padi tanpa tanah dan air di bawahnya — sehingga merepresentasikan benda itu sendiri, bukan campurannya. Keunggulan jalan ini adalah kesahihan fisiknya: spektrumnya nyata, terukur, dan dapat ditelusuri. Kelemahannya terletak pada **skala**: spektrum seperti ini diukur pada skala daun atau kanopi yang sangat kecil, sementara piksel satelit merata-ratakan luasan yang jauh lebih besar. Perbedaan skala ini, sebagaimana akan ditunjukkan pada Subbab 4.6, membawa konsekuensi yang tidak dapat dihilangkan begitu saja. Dalam pekerjaan yang dilaporkan buku ini, jalan pertama inilah yang dipakai: endmember diambil dari basis data SpecLib yang dikelola laboratorium, berisi lima kelas varietas padi.

Jalan kedua: ekstraksi dari citra. Endmember diturunkan dari citra itu sendiri, dengan mencari piksel-piksel yang paling "murni" — piksel yang spektrumnya paling ekstrem ke suatu arah, sehingga diperkirakan paling sedikit mengandung campuran. Metode-metode seperti ini bekerja murni berdasarkan geometri sebaran data, tanpa memerlukan data lapangan [3]. Keunggulannya, endmember otomatis sepadan dengan citra karena berasal dari citra itu sendiri. Kelemahannya halus tetapi menentukan: apa yang ditemukan metode ini adalah **arah variasi**, bukan **kelas benda**. Bila variasi terbesar dalam sebuah citra sawah berasal dari perbedaan fase tumbuh, bukan dari perbedaan varietas, maka metode ini akan menemukan fase sebagai "endmember" — dan hasilnya tidak akan sesuai dengan kelas varietas yang diinginkan. Jalan kedua ini juga diuji dalam pekerjaan ini, dan hasilnya dibahas pada Subbab 4.4 serta Bab 12.

Jalan ketiga: kalibrasi lapangan. Endmember dari pustaka atau dari citra disesuaikan dengan pengukuran lapangan pada petak yang varietasnya diketahui. Ini jalan yang paling mahal tetapi paling dapat dipertanggungjawabkan, karena memverifikasi hubungan antara apa yang diukur di lapangan dan apa yang terekam satelit. Jalan ini jugalah yang menutup keterbatasan terbesar pekerjaan ini: tanpa data lapangan, kita hanya dapat mengukur akurasi **pemisahan spektral**, bukan akurasi **pemetaan tematik**. Yang dibutuhkan untuk itu adalah koordinat petak contoh dengan varietas yang diketahui, minimal tiga puluh petak tersebar, pada musim (season) tanam (cropping season) yang sama dengan citra. Sampai data itu tersedia, jalan ketiga tetap menjadi arah pengembangan, bukan hasil.

4.3 Metode ekstraksi geometris: PPI dan kerabatnya

Karena jalan kedua diuji secara rinci dalam pekerjaan ini, metodenya perlu diperkenalkan lebih dahulu. Ada dua kelompok besar metode ekstraksi geometris, dan keduanya bertumpu pada gagasan yang sama: piksel murni berada di tepi sebaran data, sedangkan piksel campuran berada di tengahnya.

Pixel Purity Index (PPI). Metode ini bekerja dengan cara yang sederhana dan elegan. Bayangkan sebaran piksel di ruang spektral sebagai awan titik. Sekarang lempar sebuah garis lurus secara acak yang melewati awan itu. Piksel yang berada paling jauh di ujung garis — yaitu proyeksi terbesar dan terkecil pada arah garis itu — dicatat. Ulangi proses ini ribuan kali dengan arah yang berbeda-beda. Piksel yang paling sering muncul sebagai ujung akan memiliki hitungan tertinggi, dan piksel-piksel itulah yang paling mungkin menjadi endmember. Alasannya mudah dipahami secara geometris: dari arah mana pun, ujung awan hampir selalu berupa piksel murni, karena piksel murni berada di tepi sedangkan piksel campuran berada di dalam [3]. Garis-garis yang dilempar berfungsi sebagai alat ukur geometris yang murah dan tahan derau (noise), karena kesalahan pada satu arah akan dikoreksi oleh arah-arahan lainnya.

N-FINDR dan kerabatnya. Kelompok metode ini mencari simpleks dengan volume terbesar yang dapat dibentuk dari piksel-piksel yang ada. Idenya: karena piksel murni berada di sudut-sudut awan, simpleks dengan volume terbesar yang dapat dibentuk dari piksel nyata akan memiliki sudut-sudutnya pada piksel murni itu. Pendekatan ini terkait dengan gagasan Craig mengenai simpleks terkecil yang membungkus data, yang oleh Boardman disebut sebagai salah satu cara menentukan simpleks "terbaik" [3]. Bila PPI mencari piksel yang paling sering menjadi ujung, N-FINDR mencari kombinasi piksel yang membentuk bangun terbesar. Keduanya menuju sasaran yang sama dari arah yang berbeda.

Kedua kelompok metode ini memiliki keterbatasan yang sama, dan keterbatasan itu menjadi kunci pada Bab 12: **keduanya mencari arah variasi terbesar dalam data, bukan kelas yang benar-benar berbeda.** Sebuah piksel dapat menjadi "paling murni" dalam arti paling ekstrem secara geometris, tanpa berarti ia mewakili kelas benda yang berbeda. Bila variasi terbesar dalam citra berasal dari sumber lain — fase tumbuh, kadar

air, kondisi atmosfer — maka metode geometris akan setia menemukan sumber itu, betapapun kita menginginkan varietas.

4.4 Contoh konkret: apa yang sebenarnya ditemukan PPI

Keterbatasan di atas bukan peringatan teoretis. Dalam pekerjaan ini, PPI benar-benar dijalankan, dan hasilnya memperlihatkan keterbatasan itu dengan sangat jelas. Karena itu contoh ini layak dibahas panjang, sebab ia mengubah peringatan menjadi bukti.

Untuk menghindari penalaran yang berputar-putar — mengekstraksi endmember dari citra lalu mengujinya pada citra yang sama — desain pengujiannya dibuat anti-sirkular. Ekstraksi dilakukan pada **separuh barat** area kajian, yang memuat 1.367.326 piksel padi, sedangkan pengujian dilakukan pada **separuh timur**, yang memuat 626.590 piksel padi. Dengan begitu, endmember yang ditemukan di barat diuji pada piksel yang belum pernah "dilihatnya".

Prosedurnya: 150.000 piksel disubsampel, 2.000 garis (skewer) dilempar secara acak, dan dihasilkan 322 piksel yang dianggap paling murni. Piksel-piksel murni itu kemudian dikelompokkan dengan k-means ke dalam lima klaster, sesuai jumlah kelas varietas yang diinginkan. Ukuran klaster yang dihasilkan adalah [642, 184, 456, 19, 699] — perhatikan klaster berisi hanya 19 piksel, tanda bahwa salah satu "kelas" sebenarnya nyaris kosong.

Langkah berikutnya adalah yang paling menyingkap. Setiap endmember hasil PPI dicocokkan dengan endmember Speclib, diukur dengan sudut spektral (SAM, makin kecil makin mirip) dan korelasi bentuk.

EM hasil PPI	Paling cocok dengan	SAM	Skala	Korelasi
EM0	Inpari32	11,2°	0,426	0,9809
EM1	Inpari32_WB C	11,4°	0,100	0,9802
EM2	Mekongga	2,8°	0,552	0,9988
EM3	Inpari32_WB C	14,3°	0,517	0,9690
EM4	Inpari32	4,0°	0,543	0,9976

Ada dua temuan penting di sini. **Pertama**, kelima endmember hasil PPI ternyata hanya cocok dengan **tiga varietas berbeda**: Inpari32, Inpari32_WBC, dan Mekongga. Ciherang dan IR64 tidak muncul sebagai kelas yang terpisah. Ini konsisten dengan temuan pada Bab 3 dan Bab 10 bahwa IR64 memang tidak dapat dipisahkan dari Ciherang. **Kedua**, dua klaster yang berbeda (EM0 dan EM4) sama-sama cocok ke Inpari32. Artinya PPI menemukan **dua arah spektral** yang keduanya mengarah ke varietas yang sama — bukti bahwa yang ditemukan PPI bukan lima kelas yang berbeda, melainkan lima arah variasi.

Hasil ini mengonfirmasi sekaligus menegaskan dua hal. Di satu sisi, PPI **berhasil secara teknis**: ia mengisi convex hull dari 0,0% menjadi 51,6%, dan menurunkan RMSE dari 179,4% menjadi 23,0%. Di sisi lain, hasil fraksinya justru **kacau**: jumlah piksel ekstrem (extreme pixel) naik dua kali lipat, dari 8,873% menjadi 17,405%. Piksel ekstrem yang naik menandakan solusi terdorong ke batas simpleks — tanda bahwa endmember tidak mencakup citra. Inilah bukti konkret bahwa mengisi hull dan memperbaiki RMSE tidak sama dengan memperbaiki hasil, sebagaimana akan dibahas pada Bab 12 dan Bab 13.

4.5 Variabilitas endmember: masalah inti

Ada satu masalah yang lebih mendasar daripada pemilihan metode, dan masalah ini mendapat tinjauan khusus dalam literatur [9]. Masalahnya begini: model campuran linear mengasumsikan bahwa setiap benda memiliki **satu** spektrum tetap. Padahal kenyataannya tidak. Spektrum padi berubah tergantung pada umur tanaman, kadar air, kandungan klorofil, sudut pengambilan citra, dan kondisi atmosfer saat perekaman. Spektrum tanah berubah tergantung kadar air dan kekasaran permukaannya.

Artinya, "endmember padi" bukanlah satu titik di ruang spektral, melainkan **sekumpulan titik** yang menyebar. Model yang mengasumsikan satu titik akan menghadapi kesulitan ketika kenyataannya titik itu seharusnya berada di tempat lain. Variabilitas ini terbagi dua jenis yang perlu dibedakan dengan tegas. **Variabilitas antar-kelas** adalah perbedaan spektrum antara benda yang berbeda jenis — inilah yang ingin kita ukur, dan inilah yang menjadi dasar pemisahan. **Variabilitas dalam-kelas** adalah perbedaan spektrum di dalam satu jenis benda yang sama — inilah yang mengganggu, karena ia membuat satu kelas tampak seperti beberapa kelas yang berbeda.

Seluruh kesulitan pemisahan varietas padi bersumber dari kenyataan bahwa variabilitas dalam-kelas untuk padi bisa sebanding atau bahkan lebih besar daripada variabilitas antar-varietas. Untuk melihat mengapa, bandingkan dua ukuran dari lembar fakta. Di satu sisi, jarak spektral (spectral distance) terdekat antara dua varietas — Ciherang dan IR64 — hanya 0,1222. Di sisi lain, spektrum endmember varietas yang sama tersebar cukup lebar: nilai NIR kelima varietas merentang dari 0,5927 (Inpari32) hingga 0,8464 (Inpari32_WBC), sebuah rentang sebesar 0,2537. Rentang variabilitas yang terukur pada satu titik waktu itu sudah dua kali lipat jarak terdekat antar-varietas. Bila variabilitas dalam-kelas akibat umur tanaman dan kadar air ditambahkan, perbedaan antar-varietas yang halus itu mudah tenggelam.

Inilah alasan mengapa Bab 7, yang membahas fenologi (phenology), bukanlah bab pelengkap. Menyaring citra berdasarkan fase tumbuh adalah cara menekan variabilitas dalam-kelas, sehingga perbedaan antar-varietas yang lebih halus menjadi terlihat. Bahwa puncak EVI (heading) piksel padi dalam pekerjaan ini terpusat pada Maret 2026 — dengan median 22 Maret 2026 — memberi kita jendela waktu yang lebih sempit dan lebih seragam, sehingga variabilitas yang tidak diinginkan berkurang.

4.6 Mengukur kualitas endmember

Sebelum menjalankan penguraian, endmember yang dipilih perlu dinilai. Ada beberapa ukuran yang berguna, dan semuanya berasal dari geometri yang dibahas pada Bab 2. Tidak ada satu angka tunggal yang cukup; masing-masing menangkap aspek yang berbeda, dan yang terbaik adalah memeriksanya bersama-sama.

Jarak spektral antar endmember. Ukuran paling langsung: seberapa berbeda dua spektrum, dihitung sebagai jarak Euclidean antara dua vektor spektrum. Bila jaraknya sangat kecil, kedua kelas tidak akan dapat dipisahkan secara andal. Pada data sembilan kanal Sentinel-2, jarak antar varietas tersaji sebagai berikut.

Pasangan	Jarak (9 kanal S2)
Ciherang–IR64	0,1222 (terdekat)
Ciherang–Inpari32	0,1595
IR64–Mekongga	0,2140
IR64–Inpari32	0,2321

Pasangan	Jarak (9 kanal S2)
Inpari32–Mekongga	0,2652
Ciherang–Mekongga	0,2731
IR64–Inpari32_WBC	0,9672
Ciherang–Inpari32_WBC	1,0339
Inpari32_WBC–Mekongga	1,0636
Inpari32–Inpari32_WBC	1,1027

Yang perlu diperhatikan adalah membandingkan jarak ini dengan **derau citra**. Jarak Ciherang–IR64 sebesar 0,1222 mungkin terdengar kecil, tetapi bila derau reflektansi (reflectance) citra hanya 0,005–0,010, maka jarak itu masih belasan kali derau. Namun pengujian pada Bab 10 akan menunjukkan bahwa dengan derau 0,010, IR64 tetap jatuh: akurasi hanya 59,7%, dengan 28,9% piksel IR64 disebut sebagai Ciherang. Jadi ambang (threshold) aman bukanlah sekadar "beberapa kali derau", melainkan harus diuji langsung. Inpari32_WBC jelas merupakan kasus terpisah: jaraknya ke semua varietas lain sangat besar (di atas 0,96), menandakan ia kemungkinan diukur pada kondisi berbeda dan berperilaku sebagai pencilan, bukan sebagai kelas yang benar-benar berdekatan.

Satu pelajaran penting muncul ketika jarak diukur pada kanal yang lebih sedikit. Pada empat kanal Landsat, jarak antar varietas **menyusut sekitar setengahnya**: Ciherang–IR64 turun dari 0,1222 menjadi 0,0610 (susut 50,1%), Ciherang–Inpari32 dari 0,1595 menjadi 0,0709 (susut 55,6%), dan seterusnya. Artinya sensor dengan kanal lebih sedikit memangkas daya pisah varietas secara drastis. Inilah alasan kuantitatif mengapa Landsat tidak memadai untuk pemisahan varietas, sebagaimana dibahas pada Bab 6.

Sudut spektral (SAM). Ukuran kemiripan **bentuk**, tidak terpengaruh oleh skala. Dihitung sebagai sudut antara dua vektor spektrum; nilai nol derajat berarti bentuk kurvanya identik. Ukuran ini berguna ketika dua spektrum memiliki bentuk yang mirip tetapi tingkat kecerahannya berbeda. Pada Subbab 4.4, SAM dipakai untuk mencocokkan endmember hasil PPI dengan endmember SpecLib, dan hasilnya menyingkap bahwa Mekongga hanya berjarak $2,8^\circ$ dari endmember SpecLib — sangat mirip.

Rasio singular (singular-value ratio). Ukuran seberapa "gepeng" simpleks yang dibentuk seluruh endmember, dihitung sebagai

perbandingan antara nilai singular (singular value) terbesar dan terkecil dari matriks endmember. Rasio yang sangat besar menandakan ada arah pemisah yang sangat tipis, sehingga solusi mudah tenggelam oleh derau. Pada pekerjaan ini, rasio singular untuk sembilan kanal Sentinel-2 adalah **410,8**, sedangkan untuk empat kanal Landsat adalah **79,4**. Menariknya, angka Landsat tampak "lebih baik" karena lebih kecil, tetapi hal itu menyesatkan: Landsat lebih rendah justru karena kanal red-edge yang memisahkan varietas tidak ada di sana. Karena itu, rasio singular tidak boleh dipakai sendirian sebagai penentu kemampuan pemisahan. Yang lebih menyesatkan lagi, koreksi per kanal — yang mengubah bentuk spektrum — hampir tidak mengubah rasio singular: dari 410,8 menjadi 411,8. Artinya masalah kegagalan koreksi itu bukan soal geometri simpleks, melainkan soal rasio sinyal terhadap derau.

Cakupan convex hull. Berapa persen piksel citra yang berada di dalam simpleks yang direntang endmember. Pada pekerjaan ini, hasilnya mengejutkan dan penting: pada bidang merah–NIR, red-edge1–NIR, dan red-edge2–NIR, cakupan hullnya **0,0%**. Rata-rata hanya 2,4 dari 9 kanal yang nilainya berada dalam rentang endmember. Penyebabnya terukur dan jelas. Nilai NIR endmember terendah adalah 0,5927, sementara nilai NIR piksel padi pada jendela heading memiliki p50 sebesar 0,2884, p90 sebesar 0,3752, dan bahkan p99 hanya 0,4444. Rata-rata piksel di atas persentil 99 pun hanya 0,4730 — masih di bawah endmember tergelap. Piksel yang mencapai NIR 0,5927 hanyalah **177 dari 1.994.687 piksel (0,009%)**.

Ini bukan tanda bahwa endmember salah, melainkan pertanda ada perbedaan mendasar yang perlu dipahami: endmember SpecLib diukur pada **kanopi padi saja** melalui spektrometri pada petak contoh, sedangkan piksel Sentinel-2 berukuran 30 meter merata-ratakan luasan sekitar 900 m² yang **selalu** memuat tanah, air, pematang, dan celah antarrumpun. Nilai satelit karena itu sistematis lebih gelap. Inilah **efek pencampuran resolusi** — bukan kesalahan data, bukan salah endmember. Bab 11 membahas kasus ini secara panjang.

Yang membuktikan bahwa endmember SpecLib justru **benar** secara spektral adalah korelasi bentuk antara spektrum piksel padi "murni" dan endmember SpecLib. Untuk lima varietas, korelasinya berkisar 0,991–0,998 — hampir sempurna.

Varietas	n piksel	Koreksi k	Korelasi bentuk
Ciherang	10.775	0,636	0,9910
IR64	19.867	0,574	0,9980
Inpari32	64.034	0,591	0,9929
Inpari32_WBC	306.667	0,297	0,9940
Mekongga	1.337.589	0,568	0,9929

Korelasi setinggi ini berarti **bentuk** kurva endmember sudah sesuai dengan padi nyata di citra; yang berbeda hanyalah tingkat kecerahannya. Konfirmasi independen datang dari PPI: endmember Mekongga hasil ekstraksi citra hanya berjarak $2,8^\circ$ sudut spektral dari endmember SpecLib. Dengan demikian, endmember SpecLib adalah endmember yang sah, dan cakupan hull (hull coverage) yang nol adalah kenyataan yang harus diterima dan dilaporkan, bukan cacat yang perlu diperbaiki.

Namun perlu dicatat bahwa koreksi skalar k tidak seragam antar-varietas — berkisar dari 0,297 (Inpari32_WBC) hingga 0,636 (Ciherang) — dan bahwa rasio per kanal pun tidak seragam. Untuk Mekongga, rasio per kanal merentang dari 0,540 (B8) hingga 4,640 (B1), dengan vektor koreksi keseluruhan $[0,366 \cdot 0,444 \cdot 0,479 \cdot 0,596 \cdot 0,548 \cdot 0,548 \cdot 0,553 \cdot 0,534 \cdot 0,548]$. Ketidakseragaman inilah yang membuat penskalaan skalar tidak dapat memperbaiki cakupan hull, dan yang membuat koreksi per kanal — meski secara teori tampak lebih benar — justru merusak akurasi, sebagaimana akan ditunjukkan pada Bab 12. Pada Bab 12 juga akan terlihat bahwa koreksi per kanal membalik urutan dominasi varietas, bukti bahwa memperbaiki angka geometris tidak sama dengan memperbaiki hasil.

4.7 Kalibrasi lapangan dan arah lanjut

Dari seluruh pembahasan di atas, satu kebutuhan menonjol sebagai yang paling berharga: **data lapangan**. Tanpa data itu, kita hanya dapat mengukur akurasi pemisahan spektral, bukan akurasi pemetaan tematik. Dua hal yang tampak mirip itu sesungguhnya berbeda: yang pertama mengukur apakah kita dapat membedakan dua spektrum yang berbeda, yang kedua mengukur apakah peta yang kita hasilkan benar-benar sesuai dengan apa yang ada di sawah. Yang pertama sudah kita ukur, yaitu akurasi 91,1% pada matriks kekeliruan piksel murni. Yang kedua masih menunggu data lapangan.

Arah kedua yang menjanjikan adalah **endmember per fase tumbuh**. Endmember SpecLib mewakili padi pada fase puncak. Untuk citra pada fase lain, diperlukan endmember fase tersebut. Ini belum diuji, tetapi sekarang kita tahu bahwa penskalaan bukan penggantinya — sifat invarian skala pada Bab 3 menjelaskan mengapa. Arah ketiga, yang paling pasti hasilnya tetapi paling mahal, adalah sensor yang lebih baik: kanal red-edge tambahan pada Sentinel-2 sudah membantu, dan sensor hiperspektral akan memberikan pemisahan yang jauh lebih baik, terutama untuk pasangan Ciherang-IR64 yang jarak spektralnya paling rapat.

4.8 Yang perlu diingat dari bab ini

Pertama, ada tiga jalan memperoleh endmember — pustaka, ekstraksi citra, dan kalibrasi lapangan — dan masing-masing membawa konsekuensi berbeda pada skala dan kesahihan. Pekerjaan ini memakai pustaka SpecLib, dan menguji jalan ekstraksi citra sebagai pembanding.

Kedua, metode ekstraksi geometris mencari arah variasi terbesar, bukan kelas yang benar-benar berbeda. Contoh PPI pada Subbab 4.4 memperlihatkan ini secara konkret: dari lima klaster yang ditemukan, hanya tiga varietas yang muncul, dan dua klaster cocok ke varietas yang sama.

Ketiga, variabilitas endmember adalah masalah inti. Pemisahan varietas padi sulit justru karena variabilitas dalam-kelas bisa melebihi perbedaan antar-varietas — jarak terdekat antar-varietas (0,1222) hanya sekitar setengah rentang NIR antar-endmember (0,2537). Menekan variabilitas itu, misalnya dengan menyaring fase tumbuh, adalah langkah yang perlu, bukan pelengkap.

Keempat, kualitas endmember dinilai dengan beberapa ukuran sekaligus — jarak spektral, sudut spektral, rasio singular, dan cakupan hull — dan masing-masing menangkap aspek yang berbeda. Tidak ada satu angka tunggal yang cukup. Korelasi bentuk 0,991–0,998 membuktikan bahwa endmember SpecLib benar; cakupan hull yang nol memberitahu bahwa endmember itu diukur pada skala yang berbeda dari piksel satelit. Kedua fakta itu benar sekaligus, dan keduanya harus dilaporkan apa adanya.

BAB V METODE REDUKSI DAN PEMETAAN BAND ENDMEMBER

5.1 Dua langkah yang sering dianggap satu

Bab 4 sudah menguraikan dari mana endmember (endmember) berasal dan mengapa variabilitasnya menjadi masalah inti. Bab ini membahas langkah berikutnya — langkah yang secara teknis berdiri sendiri, tetapi sering dianggap satu paket dengan langkah memperoleh endmember: **mengubah spektrum laboratorium menjadi nilai pada kanal (band)-kanal sensor.**

Menggabungkan dua langkah itu menjadi kesalahan yang mahal, sebab keduanya menjawab pertanyaan yang berbeda, dan masing-masing punya pilihan sendiri.

Langkah pertama adalah reduksi. Spektroradiometer menghasilkan banyak ukuran pada setiap panjang gelombang. Pada data laboratorium ini, jumlahnya 3.141 titik, membentang dari 400,2 sampai 999,9 nanometer untuk setiap sampel. Jumlah sampel per varietas (variety) juga tidak sedikit: Ciherang 51 sampel, IR64 53, Inpari32 51, Inpari32_WBC 42, dan Mekongga 80. Reduksi memadatkan seluruh sampel itu menjadi **satu spektrum tunggal** yang mewakili kelas tersebut. Pertanyaannya: memadatkan dengan cara apa?

Langkah kedua adalah pemetaan band. Spektrum tunggal hasil reduksi masih berupa kurva kontinu. Sensor satelit tidak mengukur kurva kontinu; ia mengukur rata-rata energi pada beberapa rentang panjang gelombang yang lebar. Sentinel-2 hanya punya sembilan kanal antara 443 dan 865 nanometer, sedangkan spektrum yang tersedia memuat 3.141 titik. Pemetaan band mengambil nilai untuk kesembilan kanal itu. Pertanyaannya: mengambil dengan cara apa?

Kedua langkah itu menghasilkan total **lima belas kombinasi** pada basis data Speclib yang dipakai laboratorium ini: lima metode reduksi dikalikan tiga metode pemetaan. Bab ini melaporkan seluruh hasil ujinya, sekaligus menyampaikan rekomendasi beserta dasar yang dapat diperiksa.

5.2 Mengapa pilihan ini tidak boleh diabaikan

Pembaca yang baru mengenal penguraian spektral (spectral unmixing) mungkin menganggap pilihan ini persoalan teknis kecil. Anggapan itu keliru. Bab ini akan menunjukkan mengapa.

Alasannya mendasar. Seluruh pekerjaan penguraian bertumpu pada satu andaian: bahwa perbedaan antar-kelas yang ingin dipisahkan **terwakili** dalam endmember. Bila proses reduksi atau pemetaan menghapus perbedaan itu — meskipun hanya sebagian — tidak ada algoritme di belakangnya yang dapat mengembalikannya. Informasi yang hilang pada tahap ini hilang untuk selamanya.

Ada dua cara informasi dapat hilang. **Pertama**, melalui perataan yang berlebihan. Setiap metode reduksi yang mengambil rata-rata pada dasarnya menghaluskan, dan penghalusan selalu menekan perbedaan tajam. **Kedua**, melalui pilihan nilai yang tidak mewakili. Setiap metode pemetaan mengambil sebagian informasi dari rentang kanal; cara pengambilannya menentukan apa yang tersisa.

Perhatikan bahwa kedua bahaya itu bergerak berlawanan arah. Reduksi yang lebih menghaluskan memberi spektrum yang lebih stabil, tetapi kurang khas. Reduksi yang lebih mempertahankan ciri memberi spektrum yang lebih khas, tetapi lebih rentan terhadap derau (noise) pengukuran. Keseimbangan inilah yang sebenarnya diuji pada bab ini. Jawabannya tidak tunggal — bergantung pada apa yang ingin dicapai.

5.3 Lima metode reduksi

Basis data SpecLib menyediakan lima metode reduksi. Kelimanya bekerja pada sumbu yang sama — yaitu pada kumpulan sampel untuk setiap panjang gelombang — tetapi mengambil ukuran statistik yang berbeda.

Average mengambil rata-rata (mean) dari seluruh sampel pada setiap panjang gelombang. Ia memakai seluruh informasi yang tersedia, tetapi juga memberi bobot penuh kepada setiap pencilan. Satu sampel yang terukur salah akan menggeser nilai rata-rata. Penggeseran itu tidak dapat dideteksi dari hasilnya.

Median mengambil nilai tengah dari seluruh sampel pada setiap panjang gelombang. Keunggulannya langsung terasa: ia tahan terhadap

pencilan. Selama kurang dari separuh sampel tergeser, nilai median tidak berubah. Untuk data spektral lapangan, di mana sebagian pengukuran dapat terganggu oleh perubahan kondisi cahaya atau posisi alat, sifat ini bernilai besar.

Gaussian mengambil rata-rata tertimbang Gaussian. Sampel yang berada di tengah sebaran memperoleh bobot lebih besar, sedangkan sampel di tepi sebaran memperoleh bobot lebih kecil. Ia berada di antara Average dan Median: lebih tahan terhadap pencilan daripada rata-rata sederhana, tetapi tidak setahan median.

Dua metode terakhir berbeda jenis, dan perbedaannya penting untuk dipahami.

Q1 mengambil kuartil pertama, yaitu nilai pada posisi 25 persen. **Q3** mengambil kuartil ketiga, nilai pada posisi 75 persen. Keduanya **bukan** ukuran nilai tengah. Q1 menggambarkan bagian kelas yang lebih rendah reflektansinya, sedangkan Q3 menggambarkan bagian yang lebih tinggi.

Mengapa ukuran seperti itu berguna? Karena pada tanaman, sebagian keragaman reflektansi (reflectance) bukan derau, melainkan sinyal. Dua petak dengan varietas sama dapat berbeda reflektansi karena perbedaan umur, kerapatan tanam, atau kadar air — dan perbedaan itu sistematis, bukan acak. Dengan mengambil kuartil, kita memilih untuk mewakili **kondisi tertentu** dari kelas tersebut, bukan kondisi rata-ratanya. Q1 mewakili tanaman pada kondisi reflektansi rendah; Q3 mewakili kondisi reflektansi tinggi.

Konsekuensinya perlu dinyatakan dengan jelas: memilih Q1 atau Q3 berarti membuat **pilihan semantik**, bukan sekadar pilihan statistik. Endmember yang dihasilkan mewakili sebagian kelas, bukan keseluruhan kelas. Bila hasil pemetaan nanti dibandingkan dengan data lapangan, perbandingan itu harus memperhitungkan hal ini.

5.4 Tiga metode pemetaan band

Setelah spektrum tunggal diperoleh, ia harus dipetakan ke kanal-kanal sensor. Sentinel-2 memiliki lebar kanal yang berbeda-beda, dan perbedaan itu menentukan seberapa besar pengaruh pilihan pemetaan.

Average mengambil rata-rata sederhana dari seluruh nilai reflektansi yang berada dalam rentang lebar penuh pada setengah maksimum (*full*

width at half maximum, FWHM) kanal tersebut. Ia memperlakukan seluruh bagian rentang itu sebagai sama pentingnya.

Gaussian Weighting mengambil rata-rata tertimbang Gaussian di sekitar titik pusat kanal, dengan lebar penimbangan ditentukan oleh FWHM. Nilai yang berada tepat di titik pusat memperoleh bobot terbesar, sedangkan bobot menurun secara halus menuju tepi rentang. Secara fisis, cara ini lebih dekat kepada cara kerja sensor: kepekaan sensor memang paling tinggi di titik pusat dan menurun ke arah tepi.

Nearest Band tidak meratakan sama sekali. Ia mengambil nilai reflektansi pada panjang gelombang yang **paling dekat** dengan titik pusat kanal. Satu titik saja.

Perbedaan mendasar antara ketiga metode terletak pada apakah bentuk spektrum di dalam rentang kanal dipertahankan atau diratakan. Average dan Gaussian Weighting meratakan; Nearest Band tidak. Karena kanal-kanal Sentinel-2 memiliki lebar yang berbeda jauh — dari 15 nanometer pada kanal red-edge sampai 115 nanometer pada kanal inframerah dekat yang lebar — pertanyaan tentang berapa banyak perataan yang terjadi menjadi pertanyaan yang sungguh menentukan.

5.5 Cara pengujian dan mengapa metriknya berubah

Uji pada bab ini berbeda dari uji yang pernah dilakukan sebelumnya; perbedaannya perlu dijelaskan, sebab menyangkut keterbukaan hasil.

Uji awal yang dijalankan laboratorium ini — sebelum kerangka penilaian pada Bab 13 dirumuskan — menggunakan **RMSE** sebagai penentu peringkat. Cara itu terbukti keliru, dan kekeliruannya sudah dibahas panjang pada Bab 13: RMSE dapat membaik sementara hasil sesungguhnya memburuk, karena fraksi (fraction) pada FCLS bersifat invarian terhadap penskalaan.

Uji ulang pada bab ini sebab itu memakai metrik yang benar, yaitu **akurasi matriks kekeliruan (confusion matrix) piksel murni (pure pixel)**. Prosedurnya: piksel sintetis dibangkitkan dari setiap endmember dengan derau pada tingkat yang realistis (0,010), lalu diuraikan kembali, dan diperiksa apakah setiap piksel dikenali sebagai kelas asalnya. Metrik ini mengukur hal yang sebenarnya ingin diketahui: **apakah kelas-kelas dapat dipisahkan**.

Selain akurasi, empat ukuran pendamping dicatat. Pertama, akurasi pemisahan pasangan tersulit (Ciherang dan IR64). Kedua, jarak spektral (spectral distance) minimum antar kelas. Ketiga, rasio singular (singular-value ratio) sebagai ukuran kondisi geometri. Keempat, RMSE — yang terakhir ini **hanya dicatat sebagai diagnostik**, bukan sebagai penentu.

5.6 Hasil: peringkat lima belas kombinasi

Tabel berikut melaporkan seluruh lima belas kombinasi, diurutkan menurut akurasi.

#	Reduksi	Pemetaan	Akurasi	Pasangan	Jarak min	Rasio	RMSE
1	Median	Nearest Band	93,8%	99,5%	0,1226	298	167,8%
2	Q1	Nearest Band	93,4%	99,6%	0,0970	292	157,4%
3	Q3	Nearest Band	93,4%	99,6%	0,1473	305	178,6%
4	Average	Nearest Band	93,2%	99,6%	0,1045	303	168,1%
5	Gaussian	Nearest Band	93,1%	99,5%	0,1389	302	169,6%
6	Q3	Average	92,9%	99,6%	0,1435	329	177,2%
7	Q1	Average	92,3%	99,3%	0,0961	335	156,6%
8	Q3	Gaussian Weighting	92,2%	100,0%	0,1520	368	176,0%
9	Median	Average	92,2%	99,3%	0,1210	371	166,4%
10	Gaussian	Average	91,9%	99,5%	0,1382	346	168,5%
11	Average	Average	91,7%	99,4%	0,1032	360	167,1%
12	Q1	Gaussian Weighting	91,5%	99,9%	0,0983	364	155,6%
13	Median	Gaussian	91,2%	99,8%	0,1222	411	165,3%

#	Reduksi	Pemetaan	Akurasi	Pasangan	Jarak min	Rasio	RMSE
		Weighting					
14	Gaussian	Gaussian Weighting	91,1%	99,9%	0,1393	383	167,4%
15	Average	Gaussian Weighting	91,1%	99,9%	0,1062	396	166,1%

Satu hal langsung terlihat dari tabel ini, dan hal itu penting untuk menafsirkan seluruh bab: **rentang akurasi antar lima belas kombinasi hanya 2,8 poin persen**, dari 91,1 persen sampai 93,8 persen.

Artinya pilihan metode reduksi dan pemetaan **tidak mengubah kesimpulan besar** pekerjaan ini. Pada seluruh lima belas kombinasi, empat varietas tetap dapat dipisahkan dengan akurasi tinggi dan IR64 tetap menjadi yang tersulit. Yang berubah adalah **seberapa baik**, bukan **apakah**.

Kesimpulan itu sekaligus menutup satu dugaan yang mungkin muncul pada Bab 12: bahwa kegagalan empat pendekatan perbaikan di sana disebabkan oleh pilihan setelan reduksi yang kurang tepat. Ternyata tidak. Setelan reduksi dan pemetaan memang memberi perbedaan, tetapi perbedaannya terlalu kecil untuk menjelaskan kegagalan yang dilaporkan pada Bab 12.

5.7 Akurasi per varietas: siapa yang paling terbantu

Angka akurasi keseluruhan menyembunyikan hal yang paling menarik, sebab perbaikan tidak tersebar merata. Tabel berikut memperlihatkan akurasi setiap varietas pada empat kombinasi teratas, dibandingkan dengan setelan yang selama ini dipakai laboratorium.

Kombinasi	Ciherang	IR64	Inpari32	Inpari32_WBC	Mekongga
Median / Nearest Band	99,9%	73,0%	96,2%	100,0%	100,0%
Q1 / Nearest	99,9%	74,1%	93,2%	100,0%	100,0%

Kombinas i	Ciherang	IR64	Inpari32	Inpari32_ WBC	Mekongga
Band					
Q3 / Nearest Band	99,9%	70,0%	97,1%	100,0%	100,0%
Median / Gaussian Weighting	100,0%	60,2%	95,7%	100,0%	100,0%

Perhatikan kolom IR64. Varietas yang selama ini menjadi batas kemampuan pemisahan — dan yang pada Bab 11 dibahas sebagai kasus di mana pemisahan tidak mungkin dilakukan — **naik dari 60,2 persen menjadi 73,0 sampai 74,1 persen**. Itu kenaikan **13 sampai 14 poin persen**.

Kenaikan itu dicapai tanpa mengubah endmember sama sekali, tanpa mengubah citra, tanpa menambah kanal, dan tanpa mengubah algoritme. Yang berubah hanya cara memetakan spektrum ke kanal. Tiga belas poin akurasi pada varietas yang paling bermasalah adalah temuan yang layak diperhatikan.

Dari mana kenaikan itu datang? Dari baris jarak spektral, terlihat bahwa jarak Ciherang–IR64 pada Nearest Band (0,1226) hampir sama dengan pada Gaussian Weighting (0,1222) — perbedaannya hanya 0,0004, atau sekitar sepertiga persen. Jadi keunggulannya **bukan** karena jarak antar-kelas menjadi lebih longgar.

Yang berbeda justru **rasio singular**: 298 pada Nearest Band dibandingkan 411 pada Gaussian Weighting. Rasio singular mengukur kondisi geometri; nilai yang lebih kecil berarti geometri endmember lebih stabil, sehingga solusi FCLS tidak mudah terdorong ke sudut simpleks (simplex). Dengan kata lain, Nearest Band tidak membuat kelas lebih berbeda — ia membuat **solusinya lebih stabil**. Kestabilan itulah yang menolong IR64.

5.8 Mana yang lebih menentukan: reduksi atau pemetaan?

Karena ada lima metode reduksi dan tiga metode pemetaan, pertanyaan praktis yang muncul adalah: mana yang lebih penting dipilih dengan hati-hati?

Untuk menjawabnya, pengaruh masing-masing dihitung dengan merata-ratakan seluruh kombinasi pada sumbu yang lain.

Metode pemetaan	Akurasi rata-rata
Nearest Band	93,38%
Average	92,19%
Gaussian Weighting	91,39%

Metode reduksi	Akurasi rata-rata
Q3	92,82%
Median	92,38%
Q1	92,38%
Gaussian	92,02%
Average	91,99%

Selisih antara metode pemetaan terbaik dan terburuk adalah **4,54 poin persen**. Selisih antara metode reduksi terbaik dan terburuk hanya **1,16 poin persen**.

Kesimpulannya tegas: **pemilihan metode pemetaan band sekitar empat kali lebih menentukan daripada pemilihan metode reduksi**. Bila waktu uji terbatas, prioritas sebaiknya diberikan untuk memilih metode pemetaan.

Perhatikan juga pola yang muncul pada tabel pertama: **kelima baris teratas semuanya Nearest Band**. Lima metode reduksi yang berbeda, tetapi begitu dipasangkan dengan Nearest Band, kelimanya berada di peringkat satu sampai lima, sedangkan kelima baris terbawah didominasi Gaussian Weighting.

5.9 Uji silang: memutus sirkularitas

Ada satu kelemahan serius pada uji sejauh ini, dan kelemahan itu harus diakui sebelum kesimpulan diambil.

Piksel sintetis dibangkitkan dari endmember kombinasi X, lalu diuraikan dengan endmember kombinasi X. Ini bersifat **sirkular**: kombinasi yang menghasilkan endmember lebih "tajam" akan menghasilkan piksel sintetis yang lebih tajam, dan piksel yang lebih tajam lebih mudah dipisahkan. Dengan kata lain, sebuah kombinasi dapat tampak

unggul bukan karena ia lebih mampu memisahkan, melainkan karena ia menilai dirinya sendiri.

Untuk memutus sirkularitas (circularity) itu, dilakukan **uji silang**: setiap kombinasi menguraikan piksel yang dibangkitkan dari **empat belas kombinasi lain**. Dengan demikian tidak ada kombinasi yang menilai endmembernya sendiri. Uji ini dijalankan dengan 14 pembangkit dikalikan 2 benih acak, menghasilkan 28 kali uji untuk setiap kombinasi.

Metode pemetaan	Akurasi silang
Nearest Band	93,92%
Average	91,39%
Gaussian Weighting	89,38%

Metode reduksi	Akurasi silang
Q1	92,62%
Gaussian	92,39%
Average	92,29%
Median	92,24%
Q3	91,28%

Hasilnya menjawab pertanyaan itu dengan jelas: **Nearest Band tetap unggul**, dengan selisih 4,54 poin dari Gaussian Weighting — hampir persis sama dengan selisih pada uji sirkular (4,50 poin). Karena selisihnya tidak menyusut ketika sirkularitasnya dihilangkan, keunggulan itu **bukan artefak pengujian**.

Pada sumbu reduksi, hasilnya justru berubah: Q3 yang tadinya unggul (92,82%) kini menjadi **terendah** (91,28%). Ini menunjukkan bahwa keunggulan Q3 pada uji pertama sebagian berasal dari sirkularitas, dan peringkat metode reduksi **tidak stabil** — konsisten dengan selisihnya yang kecil (1,16 poin).

5.10 Uji ketahanan terhadap derau

Uji-uji sebelumnya memakai piksel sintetis; uji berikutnya memakai **piksel padi yang sesungguhnya** dari citra, yang ditambah derau pada tiga tingkat, lalu diuraikan ulang. Angka yang dilaporkan adalah persentase piksel yang kelas dominannya tetap sama setelah ditambah derau.

Kombinasi	Derau 0,005	Derau 0,010	Derau 0,020	Rata-rata
Q3 / Gaussian Weighting	82,3%	70,7%	57,1%	70,04%
Q3 / Average	81,2%	68,6%	54,5%	68,05%
Q3 / Nearest Band	81,3%	68,5%	54,2%	68,01%
Median / Gaussian Weighting	79,5%	67,3%	53,8%	66,87%
Average / Gaussian Weighting	79,3%	67,1%	53,8%	66,71%
Median / Nearest Band	78,6%	64,9%	50,7%	64,77%
Q1 / Nearest Band	76,2%	62,3%	48,7%	62,42%

Di sini urutannya **terbalik** dari uji akurasi.

Metode pemetaan	Akurasi	Ketahanan derau
Nearest Band	93,38%	64,88%
Average	92,19%	65,14%
Gaussian Weighting	91,39%	66,96%

Nearest Band paling baik dalam **memisahkan kelas**, tetapi paling lemah dalam **mempertahankan hasil ketika citra berderau**. Gaussian Weighting menunjukkan pola yang berlawanan.

Temuan ini masuk akal secara teknis, meskipun bertentangan dengan dugaan awal. Nearest Band mengambil **satu titik** dari spektrum, sehingga ia paling setia pada bentuk spektrum — dan bentuk spektrum itulah yang membedakan kelas. Tetapi karena hanya bergantung pada satu titik, ia juga paling rentan: derau pada titik itu langsung masuk ke endmember tanpa teredam. Gaussian Weighting meratakan beberapa titik, sehingga derau teredam, tetapi perataan itu juga menghaluskan bentuk yang justru membedakan kelas.

Ini adalah **kompromi klasik antara ketajaman dan kestabilan**. Tidak ada pilihan yang unggul pada keduanya sekaligus.

5.11 Dampak pada peta

Angka akurasi memberi gambaran tentang kemampuan mesin, tetapi pertanyaan yang lebih praktis adalah: seberapa besar perbedaannya pada **peta yang dihasilkan?**

Untuk menjawabnya, 300.000 piksel padi diuraikan dengan kelima belas kombinasi, lalu kelas dominan setiap piksel dibandingkan dengan setelan yang dipakai laboratorium (Median + Gaussian Weighting).

Kombinasi	Piksel berbeda	Persentase
Average / Gaussian Weighting	14.421	4,81%
Median / Average	16.758	5,59%
Average / Average	23.320	7,77%
Q3 / Average	25.564	8,52%
Q3 / Gaussian Weighting	27.259	9,09%
Median / Nearest Band	36.635	12,21%
Q1 / Nearest Band	51.456	17,15%

Perbedaan terbesar mencapai **17,15 persen piksel** — pada peta seluas 76 kali 50 kilometer, itu bukan perbedaan yang dapat diabaikan.

Yang lebih penting lagi adalah pengaruhnya pada fraksi. Tabel berikut melaporkan rentang fraksi setiap varietas di seluruh lima belas kombinasi.

Varietas	Minimum	Maksimum	Rentang	% dari rata-rata
Ciherang	0,0843	0,0940	0,0097	10,9%
IR64	0,0724	0,1313	0,0589	58,2%
Inpari32	0,0850	0,1729	0,0879	65,4%
Inpari32_WB C	0,2425	0,2558	0,0133	5,3%
Mekongga	0,3780	0,4692	0,0912	21,8%

Dua hal menonjol dari tabel ini.

Pertama, IR64 dan Inpari32 adalah kelas yang paling tidak stabil. Fraksi IR64 dapat berubah sampai 58,2 persen dari nilai rata-ratanya hanya karena pilihan setelan, dan Inpari32 sampai 65,4 persen. Kedua kelas

itu justru yang paling sulit dipisahkan. Ini bukan kebetulan: kelas yang jaraknya tipis dari kelas lain akan paling mudah berpindah sisi ketika endmember bergeser sedikit.

Sebaliknya, Ciherang (10,9 persen) dan Inpari32_WBC (5,3 persen) sangat stabil. Inpari32_WBC stabil karena jaraknya dari semua kelas lain sangat longgar — jarak terdekatnya 0,9672, jauh di atas pasangan lain.

Kedua, dan ini temuan yang menenangkan: **Mekongga tetap menjadi kelas dominan pada seluruh lima belas kombinasi**. Meskipun fraksinya berayun antara 0,3780 dan 0,4692, ia tidak pernah tergeser dari peringkat pertama.

Temuan itu menguatkan kesimpulan pada Bab 11 bahwa dominasi Mekongga bersifat nyata dan bukan artefak pemrosesan. Lima belas kombinasi setelan yang berbeda-beda — yang mengubah endmember secara cukup berarti — semuanya menghasilkan jawaban yang sama tentang kelas mana yang paling luas.

5.12 Mengapa Nearest Band unggul: hipotesis yang tidak terbukti

Sampai titik ini, satu pertanyaan masih menggantung. Mengapa Nearest Band lebih unggul? Pemahaman atas sebabnya penting: tanpa sebab yang jelas, keunggulan itu hanya berlaku untuk data ini dan belum tentu berlaku untuk data lain.

Hipotesis yang paling masuk akal pada awalnya sederhana. Average dan Gaussian Weighting meratakan nilai di dalam rentang FWHM kanal. Pada kanal yang lebar, perataan itu menghapus bentuk spektrum. Perbedaan antar-varietas padi justru terletak pada bentuk di daerah transisi merah–inframerah dekat, sehingga kanal yang lebar seharusnya paling banyak kehilangan informasi — dan pada kanal itulah Nearest Band paling diuntungkan.

Hipotesis itu **diuji dan tidak terbukti**.

Korelasi antara lebar kanal dan besarnya perbedaan antar metode hanya **+0,498** — lemah. Yang lebih meyakinkan adalah rinciannya:

Kanal	Titik pusat	FWHM	Selisih antar metode
B1	443 nm	20 nm	3,27%
B2	490 nm	65 nm	14,34%

Kanal	Titik pusat	FWHM	Selisih antar metode
B3	560 nm	35 nm	2,95%
B4	665 nm	30 nm	1,93%
B5	705 nm	15 nm	0,60%
B6	740 nm	15 nm	0,61%
B7	783 nm	20 nm	0,24%
B8	842 nm	115 nm	1,04%
B9	865 nm	20 nm	0,05%

Bila hipotesis itu benar, B8 — kanal terlebar dengan FWHM 115 nanometer — seharusnya menunjukkan perbedaan terbesar. Kenyataannya perbedaannya hanya 1,04 persen, lebih kecil daripada B1 yang lebarnya hanya 20 nanometer (3,27 persen), dan jauh lebih kecil daripada B2 (14,34 persen, FWHM 65 nanometer). Polanya tidak konsisten dengan hipotesis.

Karena itu, penyebab keunggulan Nearest Band pada pekerjaan ini belum dapat dijelaskan. Yang dapat dilaporkan hanyalah korelasi yang terukur: Nearest Band menghasilkan rasio singular terkecil (297,8 dibandingkan 410,8 pada Gaussian Weighting), sedangkan jarak antar-kelasnya hampir tidak berubah. Jadi keunggulannya tampaknya berkaitan dengan **kestabilan geometri**, bukan dengan pelestarian bentuk spektrum.

Pernyataan itu ditinggalkan sebagai hipotesis baru yang belum diuji, bukan sebagai kesimpulan. Bab 14 mencantumkannya sebagai arah uji lanjut.

5.13 RMSE: sekali lagi menyesatkan

Bab 13 sudah membahas mengapa RMSE tidak layak dijadikan penentu. Hasil pada bab ini memberi bukti tambahan yang kuat, dan buktinya layak dicatat di sini karena muncul dari data yang berbeda.

Korelasi antara akurasi dan RMSE pada kelima belas kombinasi hanya **+0,253** — lemah.

Contoh yang paling tegas adalah dua kombinasi berikut.

Q1 + Gaussian Weighting menghasilkan RMSE **terbaik** di antara seluruh lima belas kombinasi, yaitu **155,6 persen**. Tetapi akurasinya hanya 91,5 persen, dan peringkatnya ke-12 dari 15.

Median + Nearest Band menghasilkan RMSE **167,8 persen** — lebih buruk 12 poin dari yang di atas. Tetapi akurasinya **93,8 persen**, tertinggi di antara seluruh kombinasi.

Bila peringkat ditentukan oleh RMSE, kombinasi terbaik pada pekerjaan ini akan terpilih sebagai kombinasi **ke-12**. Ini contoh yang paling jelas dari pelajaran yang dibahas pada Bab 13: **metrik yang salah akan menunjukkan perbaikan pada setiap perubahan, termasuk perubahan yang merusak.**

5.14 Rekomendasi dan dasar pemilihannya

Berdasarkan seluruh uji pada bab ini, setelan yang direkomendasikan untuk pekerjaan pemetaan varietas padi di laboratorium ini adalah:

Median sebagai metode reduksi, Gaussian Weighting sebagai metode pemetaan band.

Rekomendasi ini dipilih dengan pertimbangan yang perlu dinyatakan secara terbuka, karena pada satu ukuran ia bukan yang terbaik.

Pada **akurasi pemisahan**, kombinasi ini berada di peringkat **ke-13 dari 15**, dengan akurasi 91,2 persen. Kombinasi dengan akurasi tertinggi adalah Median + Nearest Band, dengan 93,8 persen.

Pada **ketahanan (robustness) terhadap derau citra**, kombinasi ini berada di peringkat **ke-2**, dengan 66,87 persen — hanya sedikit di bawah Q3 + Gaussian Weighting (70,04 persen).

Dasar pemilihannya adalah sebagai berikut.

Pertama, hasil pemetaan akan dipakai pada citra nyata, yang selalu berderau. Akurasi pemisahan diukur pada piksel sintetis dengan derau yang dikendalikan; hasil sebenarnya akan diterapkan pada citra dengan derau yang tidak diketahui besarnya dan dapat lebih besar. Dalam keadaan itu, ketahanan menjadi lebih penting daripada ketajaman.

Kedua, Median tahan terhadap pencilan. Data spektral lapangan selalu memuat sebagian pengukuran yang terganggu. Median memastikan bahwa pengukuran-pengukuran itu tidak menggeser endmember, sedangkan Average tidak memberi jaminan seperti itu.

Ketiga, Gaussian Weighting secara fisis lebih dekat kepada cara kerja sensor. Kepekaan sensor memang paling tinggi di titik pusat kanal

dan menurun ke arah tepi. Mengambil satu titik (Nearest Band) mengabaikan sifat itu.

Keempat, kestabilan lintas-percobaan. Median konsisten berada pada peringkat atas di kedua ukuran, sedangkan Q3 — yang unggul pada akurasi uji pertama — justru menjadi terendah pada uji silang. Kombinasi yang stabil lebih dapat diandalkan daripada kombinasi yang unggul pada satu ukuran saja.

Namun rekomendasi ini perlu disertai catatan yang terbuka. Catatan itu bagian penting dari kesimpulan bab ini.

Bila tujuan utama adalah akurasi pemisahan maksimum — misalnya untuk kajian yang khusus membandingkan varietas dengan jarak spektral tipis seperti Ciherang dan IR64 — maka **Median + Nearest Band** lebih tepat, karena menaikkan akurasi IR64 dari 60,2 persen menjadi 73,0 persen. Untuk keperluan itu, selisih 13 poin bukan selisih yang dapat diabaikan.

Bila pekerjaan menyangkut Q3 atau Q1 — misalnya untuk kajian yang secara khusus ingin mewakili kondisi tanaman pada reflektansi tertentu — maka perlu diingat bahwa kedua metode itu menghasilkan endmember yang mewakili **sebagian kelas, bukan seluruhnya**. Hasilnya tidak boleh dibandingkan langsung dengan data lapangan tanpa memperhitungkan hal itu.

Perlu juga dinyatakan bahwa seluruh pengujian pada bab ini masih bertumpu pada piksel sintesis atau pada acuan internal (kelas dominan), bukan pada kebenaran lapangan. Selisih 2,8 poin yang memisahkan peringkat pertama dan terakhir berada di dalam batas ketidakpastian yang hanya dapat dipersempit oleh data lapangan. Sebab itu, rekomendasi di atas sebaiknya dibaca sebagai **pilihan awal yang wajar**, bukan sebagai kesimpulan akhir.

5.15 Jebakan teknis

Tiga hal teknis ditemukan selama uji ini, dan ketiganya berpotensi menyebabkan kesalahan yang sulit dilacak.

Pertama, tipe data pada masker (mask). Berkas masker padi disimpan sebagai bilangan bulat delapan bit bernilai nol dan satu, **bukan** sebagai tipe logika. Ketika dipakai langsung sebagai indeks, NumPy

menafsirkan nilai nol dan satu itu sebagai **posisi indeks**, bukan sebagai masker kebenaran. Akibatnya jumlah piksel yang diproses membengkak dari 1.994.687 menjadi 4.279.431 — yaitu seluruh piksel sah — tanpa pesan kesalahan apa pun. Program tetap berjalan dan menghasilkan angka; angka itu saja yang tidak bermakna. Perbaikannya satu kata: ubah ke tipe logika sebelum dipakai sebagai masker.

Kedua, nama kunci pada antarmuka pemrograman. Fungsi reduksi pada Speclib menerima kunci `em_ids` berisi daftar pengenalan yang dipisahkan koma, dan kunci method untuk metode reduksi. Kunci lain yang tampak lebih wajar — `endmember_ids` atau `reduction_method` — **tidak dikenali**. Kesalahannya muncul sebagai pesan "pilih minimal dua endmember" yang menyesatkan, seolah masalahnya pada jumlah endmember, padahal masalahnya pada nama kunci.

Ketiga, orientasi matriks pada FCLS. Matriks endmember yang dipakai penyelesaian FCLS berorientasi **kanal dikali kelas**, bukan kelas dikali kanal. Menggunakan orientasi yang terbalik menghasilkan galat bentuk yang jelas, tetapi orientasi yang benar pada satu fungsi dan terbalik pada fungsi lain dapat lolos tanpa peringatan. Sebab itu, konvensi orientasi perlu dituliskan pada setiap fungsi, bukan hanya diingat.

Selain ketiganya, satu catatan tentang uji yang diulang. Uji awal menggunakan RMSE dan **tidak menyimpan hasilnya ke berkas** — hanya mencetaknya. Ketika hasilnya diperlukan kembali, angkanya sudah tidak dapat diperoleh, dan uji itu harus dijalankan ulang dengan metrik yang berbeda. Pelajarannya sederhana: **setiap pengujian harus menyimpan hasilnya**, karena nilai sebuah pengujian tidak berhenti pada saat ia selesai dijalankan.

5.16 Yang perlu diingat dari bab ini

Pertama, reduksi dan pemetaan band adalah dua langkah yang berbeda. Reduksi memadatkan banyak sampel menjadi satu spektrum; pemetaan mengambil nilai untuk kanal-kanal sensor. Keduanya punya pilihan sendiri, dan pilihan itu menentukan informasi apa yang bertahan sampai ke tahap penguraian.

Kedua, terdapat lima metode reduksi (Average, Gaussian, Median, Q1, Q3) dan tiga metode pemetaan band (Average, Gaussian Weighting, Nearest Band), menghasilkan lima belas kombinasi.

Ketiga, pilihan metode **pemetaan band** sekitar empat kali lebih menentukan daripada pilihan metode **reduksi** (4,54 poin berbanding 1,16 poin).

Keempat, rentang akurasi antar kelima belas kombinasi hanya 2,8 poin, sehingga pilihan setelan **tidak mengubah kesimpulan besar** pekerjaan ini. Empat varietas tetap dapat dipisahkan dan IR64 tetap yang tersulit.

Kelima, pada akurasi pemisahan, **Median + Nearest Band** tertinggi (93,8 persen) dan menaikkan akurasi IR64 dari 60,2 menjadi 73,0 persen. Pada ketahanan derau (noise robustness), **Q3 + Gaussian Weighting** tertinggi (70,04 persen). Tidak ada kombinasi yang unggul pada keduanya sekaligus.

Keenam, rekomendasi laboratorium adalah **Median + Gaussian Weighting**, dipilih atas dasar ketahanan terhadap derau, ketahanan Median terhadap pencilan, kedekatan Gaussian Weighting dengan cara kerja sensor, dan kestabilan lintas-percobaan. Untuk keperluan yang menuntut akurasi pemisahan maksimum, Median + Nearest Band lebih tepat.

Ketujuh, IR64 dan Inpari32 adalah kelas yang paling tidak stabil terhadap pilihan setelan (fraksi dapat berubah 58,2 dan 65,4 persen), sedangkan Mekongga tetap dominan pada seluruh lima belas kombinasi.

Kedelapan, RMSE kembali terbukti menyesatkan: kombinasi dengan RMSE terbaik (155,6 persen) berada di peringkat ke-12 berdasarkan akurasi.

Kesembilan, penyebab keunggulan Nearest Band belum dapat dijelaskan. Hipotesis tentang pengaruh lebar kanal tidak terbukti (korelasi hanya +0,498).

BAB VI MEMILIH SENSOR: MENGAPA SENTINEL-2, BUKAN LANDSAT

6.1 Pilihan sensor bukan soal selera

Ketika pekerjaan pemetaan varietas (variety) dimulai, pertanyaan pertama yang muncul adalah sensor mana yang dipakai. Jawabannya tidak boleh ditentukan oleh kebiasaan atau ketersediaan, karena sensor menentukan apa yang **mungkin** dikerjakan. Sensor yang salah kanal (band) tidak dapat memisahkan varietas, sebagus apa pun algoritme yang dipakai di belakangnya.

Bab ini membandingkan tiga kelompok sensor yang tersedia, menjelaskan mengapa Sentinel-2 dipilih, dan — ini bagian yang penting — melaporkan pengujian lintas-sensor dengan Landsat 9 yang justru mengonfirmasi bahwa data Sentinel-2 yang dipakai memang sah.

6.2 Apa yang dibutuhkan untuk memisahkan varietas

Untuk memisahkan dua varietas padi, keduanya harus **berbeda secara spektral** pada kanal-kanal yang tersedia. Semakin kecil perbedaannya, semakin sulit pemisahan, dan semakin besar kemungkinan derau (noise) citra menutupi perbedaan itu.

Perbedaan antar-varietas padi paling terlihat pada daerah **red-edge**, yaitu rentang panjang gelombang antara merah dan inframerah dekat, sekitar 680 sampai 750 nanometer. Pada rentang ini, reflektansi (reflectance) daun berubah sangat cepat karena transisi dari penyerapan klorofil yang kuat di kanal merah menuju pemantulan yang kuat oleh struktur daun di inframerah dekat. Bentuk kurva di daerah ini peka terhadap kandungan klorofil, kerapatan kanopi (canopy), dan struktur daun — tiga hal yang membedakan varietas padi [6,7].

Sentinel-2 adalah misi pengamatan Bumi optik pertama yang menyertakan **tiga kanal** di daerah red-edge [8]. Kanal-kanal itu berada pada 705, 740, dan 783 nanometer.

Bahwa kanal red-edge benar-benar menambah informasi, bukan sekadar menambah jumlah kanal, sudah diuji secara sistematis dalam literatur. Forkuor dan rekan membandingkan Landsat-8 dengan Sentinel-2 untuk pemetaan tutupan lahan di Burkina Faso dan menyimpulkan bahwa kehadiran kanal red-edge memberi nilai tambah yang nyata terhadap

ketelitian pemetaan [6]. Qiu dan rekan sampai pada kesimpulan searah ketika menguji secara khusus kanal vegetasi red-edge Sentinel-2 untuk memperbaiki klasifikasi tutupan lahan [7]. Kedua kajian itu tidak dilakukan pada padi, tetapi mekanismenya sama: kanal tambahan di daerah transisi merah–inframerah dekat menangkap perbedaan yang tidak terlihat oleh kanal lebar. Untuk padi, di mana varietas dibedakan oleh kerapatan kanopi dan kandungan klorofil, keuntungan itu menjadi lebih besar lagi. Landsat, baik generasi 8 maupun 9, tidak memiliki satu pun kanal di daerah itu.

Inilah dasar teknis pemilihan sensor, dan inilah yang menjelaskan mengapa hasil pengujian pada Bab 10 dan 11 menunjukkan Landsat tidak memadai untuk pemisahan varietas, meskipun ia tetap berguna untuk keperluan lain.

6.2.1 Mengapa klorofil menciptakan tebing red-edge

Agar pilihan sensor tidak sekadar dihafal, perlu dipahami mengapa daerah red-edge ada sama sekali. Pada daun yang sehat, pigmen klorofil menyerap cahaya dengan sangat kuat pada kanal merah, yaitu sekitar 665 nanometer. Penyerapan itu bukan kebetulan: klorofil memang menggunakan energi pada panjang gelombang tersebut untuk fotosintesis. Akibatnya, pada kanal merah, daun yang rimbun memantulkan sangat sedikit cahaya — reflektansinya rendah.

Sesaat setelah 700 nanometer, kemampuan klorofil menyerap cahaya menurun tajam. Pada saat yang sama, struktur internal daun mulai memantulkan cahaya inframerah dekat dengan kuat. Kedua hal ini bertemu pada rentang yang sempit, dan hasilnya adalah kenaikan reflektansi yang curam — dari sekitar 0,05 pada kanal merah menjadi 0,4 atau lebih pada inframerah dekat, hanya dalam rentang beberapa puluh nanometer. Kecuraman inilah yang disebut tebing red-edge (red-edge cliff).

Yang penting untuk pekerjaan ini: **posisi** tebing itu, bukan hanya tingginya, bergeser menurut kandungan klorofil. Daun dengan klorofil lebih banyak menyerap cahaya sampai panjang gelombang yang lebih panjang, sehingga tebingnya bergeser ke arah inframerah. Varietas padi yang berbeda memiliki kandungan klorofil dan kerapatan kanopi yang berbeda, sehingga tebing red-edge mereka berada pada posisi yang sedikit berbeda. Perbedaan posisi itu tidak terlihat pada kanal merah atau inframerah dekat saja — ia hanya terlihat bila ada kanal yang mengintai tepat di tengah tebing. Tiga kanal red-edge Sentinel-2 pada 705, 740, dan

783 nanometer adalah tiga titik pengamatan yang sengaja ditempatkan di sana [8].

6.2.2 Struktur daun dan hamburan internal

Faktor kedua yang membedakan varietas adalah struktur daun. Daun bukan benda padat yang memantulkan cahaya dari permukaannya saja. Di dalam daun terdapat rongga udara dan jaringan bunga karang yang menyebabkan cahaya inframerah dekat mengalami hamburan berkali-kali sebelum keluar kembali. Karena klorofil tidak menyerap inframerah dekat, hampir seluruh cahaya yang masuk akhirnya dipantulkan keluar, sehingga daun tampak sangat terang pada kanal ini.

Kerapatan kanopi menentukan berapa banyak lapisan daun yang dilalui cahaya sebelum kembali ke sensor. Varietas padi yang tumbuh lebih rimbun, dengan daun yang lebih lebar dan lebih banyak, memantulkan inframerah dekat lebih kuat daripada varietas yang kanopinya lebih jarang. Pada data laboratorium ini, perbedaan itu terlihat pada nilai inframerah dekat endmember (endmember): Inpari32 memiliki nilai terendah, 0,5927, sedangkan Inpari32_WBC memiliki nilai tertinggi, 0,8464. Rentang 0,5927 sampai 0,8464 itu bukan perbedaan kecil — ia mencerminkan perbedaan struktur kanopi yang nyata antar-varietas. Perlu dicatat, bagaimanapun, bahwa perbedaan struktur daun lebih banyak terlihat pada inframerah dekat, sedangkan perbedaan klorofil lebih banyak terlihat pada red-edge. Karena itu keduanya diperlukan, dan sensor yang kehilangan salah satunya kehilangan sebagian daya pisah.

6.2.3 Kandungan air dan wilayah inframerah gelombang pendek

Faktor ketiga adalah kandungan air. Daun padi yang masih muda dan berair banyak menyerap cahaya pada inframerah gelombang pendek (shortwave infrared), sedangkan daun yang mulai mengering memantulkannya lebih kuat. Kandungan air karena itu menjadi pembeda tambahan, dan ia juga menjadi alasan mengapa fase tumbuh sangat memengaruhi spektrum — persoalan yang dibahas panjang pada Bab 7.

Dengan ketiga faktor ini — klorofil, struktur daun, dan kandungan air — menjadi jelas bahwa pemisahan varietas bukan pekerjaan satu kanal. Ia menuntut sensor yang mengamati beberapa bagian spektrum sekaligus, dan yang paling menentukan adalah bagian red-edge, karena di situlah ketiga faktor bertemu dan saling memperkuat.

6.3 Tiga sensor dibandingkan

Untuk membandingkan secara kuantitatif, dua ukuran dipakai: **rasio singular (singular-value ratio)** sebagai ukuran kondisi geometri endmember, dan **jarak spektral (spectral distance) minimum antar varietas** sebagai ukuran seberapa sulit pemisahan yang paling sulit.

Sensor	Kanal	Red-edge	Rasio singular	Jarak min antar varietas
Landsat 8/9	5	0	10.937	0,0681
Sentinel-2 MSI	9	3	411	0,1222
WorldView-2/3	8	1 (kanal kuning)	249	0,3079

Angka-angka ini perlu dibaca dengan hati-hati. **Rasio singular yang lebih rendah tidak otomatis berarti lebih mampu memisahkan.** Perhatikan bahwa Landsat memiliki jarak antar-varietas paling kecil — artinya varietas paling sulit dibedakan — tetapi rasio singularnya justru paling besar. Kedua ukuran ini mengukur hal yang berbeda: rasio singular mengukur kestabilan solusi, sedangkan jarak mengukur seberapa besar perbedaan yang harus dideteksi.

Yang menentukan kemampuan memisahkan adalah **jarak antar-varietas dibandingkan derau citra**. Dengan derau reflektansi permukaan Landsat sekitar 0,01 sampai 0,02, jarak 0,0681 hanya tiga sampai tujuh kali derau. Itu batas yang terlalu tipis untuk dapat diandalkan. Pada Sentinel-2, jarak 0,1222 dengan derau yang sebanding memberi margin lebih longgar.

Perlu dicatat juga bahwa jarak minimum itu melibatkan pasangan Ciherang dan IR64. Pasangan lain pada Sentinel-2 memiliki jarak yang jauh lebih lega — pasangan Ciherang–Inpari32_WBC mencapai 1,03. Jadi angka minimum itu menggambarkan **kasus terburuk**, bukan gambaran keseluruhan.

6.4 Mengapa Landsat memangkas jarak antar-varietas

Pada Bab 6 ini dilaporkan hasil pengujian yang membandingkan endmember SpecLib setelah diproyeksikan ke kanal-kanal Landsat dengan endmember pada kanal-kanal Sentinel-2. Proyeksi dilakukan dengan memilih kanal yang berpadanan: biru, hijau, merah, dan inframerah dekat.

Hasilnya konsisten dan mudah dipahami:

Pasangan varietas	4 kanal Landsat	9 kanal Sentinel-2	Penyusutan
Ciherang–IR64	0,0610	0,1222	–50,1%
Ciherang–Inpari32	0,0709	0,1595	–55,6%
Ciherang–Mekongga	0,1225	0,2731	–55,2%
IR64–Mekongga	0,1162	0,2140	–45,7%
Inpari32–Mekongga	0,1443	0,2652	–45,6%

Seluruh pasangan menyusut sekitar setengahnya. Penyebabnya jelas: lima kanal yang hilang — termasuk ketiga kanal red-edge — adalah kanal-kanal yang justru paling banyak memuat perbedaan antar-varietas. Yang tersisa hanyalah kanal-kanal yang mengukur hal-hal yang lebih umum: kecerahan, kehijauan secara kasar, dan kandungan air.

Perlu dicatat bahwa rasio singular Landsat justru **lebih kecil** — 79,4 dibandingkan 410,8 untuk Sentinel-2. Ini bisa menyesatkan bila dibaca tanpa konteks. Rasio singular yang lebih kecil hanya berarti geometri endmember lebih stabil; ia tidak berarti endmember itu lebih mampu memisahkan, karena yang menentukan kemampuan memisahkan adalah jarak antar-kelas. Pada Landsat, geometrinya memang lebih stabil tetapi perbedaan antar-varietasnya justru menyusut menjadi setengah.

6.5 Kuantifikasi: dari bilangan bulat ke reflektansi

Sebelum data dapat dipakai, satu langkah teknis harus dilakukan, dan langkah ini sering menjadi sumber kesalahan yang tidak terdeteksi.

Citra satelit disimpan sebagai **bilangan bulat** untuk menghemat ruang, bukan sebagai nilai reflektansi. Pada Sentinel-2, nilai yang tersimpan harus dibagi 10.000. Pada Landsat Collection 2, nilai harus dikalikan 0,0000275 lalu dikurangi 0,2.

Konsekuensi bila langkah ini terlewat sangat besar. Nilai Sentinel-2 yang belum dikuantifikasi berkisar ratusan, sedangkan endmember SpecLib berkisar antara 0 dan

1. Membandingkan keduanya berarti membandingkan nilai orde ratusan dengan nilai

orde perseratus — selisih empat orde besaran. Hasilnya pasti salah total, dan yang lebih berbahaya, kesalahannya tidak selalu terlihat sebagai kegagalan program. Program tetap berjalan dan menghasilkan angka; angkanya saja yang tidak bermakna.

Pengujian pada data ini memperlihatkan nilainya dengan jelas. Sebelum kuantifikasi, kanal merah Sentinel-2 memiliki nilai rata-rata 665,28 dan kanal inframerah dekat 2.342,67. Setelah dibagi 10.000, nilainya menjadi 0,0665 dan 0,2343 — dalam rentang yang sama dengan endmember, dan barulah perbandingan menjadi sah.

Ada satu jebakan tambahan yang ditemukan saat mengerjakan ini: bila kanal klasifikasi awan ikut dibagi 10.000 bersama kanal spektral, nilai kelasnya rusak. Kanal *Scene Classification Layer* menyimpan kelas berupa bilangan bulat 0 sampai 11; setelah dibagi 10.000, nilainya menjadi 0,0004 dan seterusnya, sehingga penyaringan awan gagal total dan tidak ada satu piksel pun yang lolos. Perbaikannya sederhana: kalikan kembali dengan 10.000 sebelum dipakai.

6.6 Validasi lintas-sensor: Landsat 9 mengonfirmasi Sentinel-2

Sampai titik ini, seluruh analisis bertumpu pada satu sensor. Pertanyaan yang wajar muncul: bagaimana kita tahu bahwa data Sentinel-2 yang dipakai memang benar? Kesalahan sistematis pada satu sensor tidak akan terdeteksi oleh analisis internal.

Untuk menjawabnya, dilakukan pengujian lintas-sensor. Citra Landsat yang tersedia di basis data laboratorium ternyata diambil pada 17 Maret 2021 — lima tahun sebelum jendela analisis. Karena itu citra itu tidak dapat dipakai. Yang dipakai adalah **Landsat 9 scene 23 Maret 2026**, hanya sehari setelah tanggal pembungaan (flowering) median (22 Maret 2026), dengan tutupan awan 13,4 persen.

Kedua citra diunduh pada grid geografis yang sama, pada resolusi 60 meter, sehingga setiap piksel dapat dibandingkan secara langsung.

Hasil pertama: cakupan scene perlu diperiksa

Sebelum perbandingan, satu hal penting ditemukan. Scene Landsat 9 yang dipilih berada pada path/row 121/065, dan **hanya menutupi 36,5**

persen dari area kajian. Sisanya bernilai nol. Bila hal ini tidak diperiksa, hasilnya akan menyesatkan: piksel nol menyebabkan indeks vegetasi membagi dengan hampir nol, sehingga nilai NDVI meledak menjadi ribuan dan rata-ratanya menjadi tidak bermakna.

Setelah piksel nol dibuang, perbandingan dilakukan pada 333.818 piksel yang benar-benar bertumpang-tindih.

Hasil kedua: kedua sensor sepakat

Ukuran	Nilai
NDVI Landsat 9	0,6434 (simpangan baku 0,2627)
NDVI Sentinel-2	0,5755 (simpangan baku 0,2787)
Korelasi	0,839
RMSE	0,1687
Bias median	-0,0505
Regresi	$S2 = 0,890 \times L9 + 0,003$

Kemiringan regresi 0,890 mendekati satu, dan intersepnnya mendekati nol. Artinya kedua sensor mengukur hal yang sama, dengan perbedaan sistematis yang kecil — Landsat sedikit lebih tinggi, yang konsisten dengan perbedaan lebar kanal merah antara kedua sensor.

Masker (mask) padi yang dibangun dari masing-masing sensor juga sepakat: presisi 90,1 persen, recall 98,1 persen, dan F1 93,9 persen. Dengan kata lain, hampir seluruh piksel yang dinyatakan padi oleh satu sensor juga dinyatakan padi oleh sensor lain.

Hasil ketiga: hull juga kosong di Landsat

Ini bagian yang paling penting dari pengujian lintas-sensor, dan hasilnya akan dipakai pada Bab 11.

Seperti akan dibahas panjang pada Bab 11, seluruh piksel padi pada citra Sentinel-2 berada di **luar** convex hull endmember Speclib — nol persen berada di dalam. Pertanyaan yang muncul: apakah ini akibat sesuatu yang spesifik pada Sentinel-2?

Jawabannya tegas: **tidak**. Ketika uji yang sama dijalankan pada data Landsat 9, hasilnya identik — nol persen piksel di dalam hull, pada ketiga bidang kanal yang diuji (merah–inframerah dekat, hijau–inframerah dekat, biru–inframerah dekat).

Temuan ini mengubah status kesimpulan Bab 11 secara mendasar. Sebelum pengujian ini, hull yang kosong masih dapat diduga sebagai akibat karakteristik kanal Sentinel-2 atau sebagai akibat kesalahan pemrosesan. Setelah pengujian ini, kedua dugaan itu tertutup. Kondisi tersebut bersifat **universal**: ia terjadi pada sensor mana pun, karena penyebabnya bukan sensor, melainkan perbedaan mendasar antara cara endmember diukur dan cara piksel satelit terbentuk.

6.7 Cara kerja kanal Sentinel-2 secara teknis

Setelah alasan pemilihan dijelaskan, ada baiknya pembaca memahami bagaimana sensor itu benar-benar bekerja, karena banyak keputusan teknis pada bab-bab berikutnya bertumpu pada rincian ini.

Sentinel-2 membawa instrumen **MSI** (*MultiSpectral Instrument*) yang mengamati Bumi pada tiga kelompok resolusi spasial. Empat kanal berada pada resolusi 10 meter: biru (490 nm), hijau (560 nm), merah (665 nm), dan inframerah dekat (842 nm). Tiga kanal red-edge berada pada resolusi 20 meter: 705, 740, dan 783 nanometer. Kanal lain — termasuk kanal 443 nanometer dan 865 nanometer yang dipakai dalam pustaka endmember laboratorium ini — juga berada pada resolusi 20 atau 60 meter. Rangkaian sembilan kanal inilah yang dipakai sepanjang buku ini, dengan pusat-pusat kanal 443, 490, 560, 665, 705, 740, 783, 842, dan 865 nanometer.

Perbedaan resolusi itu bukan kekurangan, melainkan konsekuensi langsung dari fisika instrumen. Setiap kanal memiliki **lebar pita** (*bandwidth*) yang berbeda, dan lebar pita menentukan berapa banyak cahaya yang diterima. Kanal-kanal yang lebar menangkap lebih banyak foton, sehingga dapat dibagi ke dalam piksel yang lebih kecil tanpa kehilangan mutu. Sebaliknya, kanal red-edge harus sempit — hanya sekitar 15 sampai 20 nanometer — karena tujuannya justru menangkap **kemiringan** tebing red-edge. Bila kanal red-edge dibuat lebar, ia akan mencampur bagian merah yang curam dengan bagian dataran inframerah, dan ketajaman yang menjadi alasan keberadaannya akan hilang.

Kanal sempit menangkap lebih sedikit foton. Untuk mempertahankan rasio sinyal terhadap derau yang memadai, luas tiap piksel harus diperbesar — dan di situlah resolusi 20 meter berasal. Jadi angka 20 meter bukan pilihan sembarang, melainkan kompromi yang dirancang antara ketajaman

spektral dan mutu radiometri. Konsekuensi praktisnya penting: begitu kita memakai kanal red-edge, kita sudah bekerja pada grid 20 meter, dan seluruh kanal lain harus diselaraskan ke grid itu agar perbandingan antar-kanal sah.


6.8 Mengapa resolusi 20 meter penting untuk petak sawah Indonesia

Pada lanskap pertanian Eropa atau Amerika, satu petak dapat membentang puluhan hektar, sehingga piksel 30 meter sekalipun masih banyak yang murni. Lanskap sawah Indonesia berbeda. Petak-petak di dataran pantai utara Jawa Barat umumnya sempit, dibatasi pematang, dan bercampur dengan permukiman, kebun, dan saluran irigasi dalam jarak yang dekat. Sebagian petak hanya beberapa ratus meter persegi.

Pada grid 10 meter, satu piksel mewakili 100 meter persegi; pada 20 meter, 400 meter persegi; pada 30 meter, 900 meter persegi. Semakin besar piksel, semakin besar kemungkinan satu piksel memuat campuran sawah, pematang, dan tanaman lain. Untuk pemetaan tutupan lahan kasar, percampuran itu masih dapat ditoleransi. Untuk pemisahan varietas, ia merusak — karena endmember yang kita bandingkan adalah spektrum varietas murni, sedangkan piksel yang tercampur bukan spektrum varietas murni mana pun.

Di sinilah dua keunggulan Sentinel-2 bertemu. Resolusi 10 meter pada kanal merah dan inframerah dekat berarti indeks vegetasi seperti NDVI dihitung pada piksel yang cukup halus untuk memisahkan petak, sedangkan kanal red-edge pada 20 meter memberi informasi spektral tambahan yang tidak dimiliki sensor lain pada resolusi sebanding. Landsat, dengan kanal 30 meter dan tanpa red-edge, kalah pada kedua sisi sekaligus. Perlu ditegaskan bahwa 20 meter bukan berarti setiap piksel pasti murni — pada petak yang sangat sempit, percampuran tetap terjadi, dan itulah sebab masker padi pada Bab 8 dibutuhkan. Yang dimaksud di sini adalah bahwa pada skala petak sawah Indonesia, resolusi 20 meter masih memberi peluang yang layak, sedangkan 30 meter sering sudah terlambat.

6.8.1 Bukti terukur: apa yang sebenarnya hilang ketika piksel membesar



Gambar 6.1. Hasil uji GSD pada satu adegan WorldView-2 Ngawi: detail spasial yang tersisa dan jarak spektral minimum antar-varietas pada sepuluh ukuran piksel.

Argumen di atas masih bersifat penalaran. Untuk mengujinya, satu adegan WorldView-2 di Ngawi (Jawa Timur) pada 25 Mei 2023 — fase generatif, tutupan awan 0,000 persen, resolusi asli 2 meter — diagregasi ke sepuluh ukuran piksel, dari 2 meter sampai 500 meter. Seluruh pengamatan dilakukan pada **adegan yang sama**: lokasi, tanggal, sensor, sudut matahari, dan atmosfer identik. Satu-satunya yang berubah adalah ukuran piksel. Karena itu setiap perbedaan hasil dapat diatribusikan kepada resolusi spasial, bukan kepada perbedaan wilayah atau musim.

Perlu dicatat bahwa data ini bertingkat **Level 1** — sudah dikoreksi radiometrik dan geometrik, tetapi belum dikoreksi atmosfer — sehingga pengolahan pada bagian ini mencakup koreksi atmosfer dengan model 6S [19] melalui perangkat **6S Natural** [21] lebih dahulu. Alasan mengapa langkah itu tidak boleh dilewati, beserta kepekaannya terhadap parameter aerosol, dijelaskan pada Bab 9.4.1. Rincian sumber data dan pengolahannya ada pada Bab 16 bagian B.

Hasilnya disajikan pada Tabel 6.7 sampai Tabel 6.9. Ukuran yang dipakai adalah **simpangan baku NDVI**, yaitu seberapa besar keragaman nilai antar-piksel, dinyatakan relatif terhadap nilai pada 2 meter.

Tabel 6.7 Detail spasial yang tersisa menurut ukuran piksel (adegan WorldView-2 Ngawi, 25 Mei 2023).

GSD (m)	Jumlah piksel	Simpangan baku NDVI	Detail tersisa	Rentang NDVI p5–p95
2	6.227.569	0,1275	100,0 %	0,272–0,686
4	1.555.508	0,1237	97,0 %	0,279–0,682

GSD (m)	Jumlah piksel	Simpangan baku NDVI	Detail tersisa	Rentang NDVI p5–p95
6	690.652	0,1201	94,2 %	0,286–0,679
10	248.138	0,1143	89,7 %	0,300–0,674
20	61.875	0,1047	82,1 %	0,328–0,667
30	27.385	0,0979	76,8 %	0,346–0,661
60	6.795	0,0848	66,5 %	0,378–0,650
100	2.359	0,0751	58,9 %	0,395–0,640
250	360	0,0592	46,4 %	0,427–0,622
500	83	0,0515	40,4 %	0,440–0,598

Temuan pertama, dan yang paling mudah menyedatkan: rerata NDVI **tidak berubah** sama sekali. Nilainya 0,534 pada 2 meter dan 0,533 pada 250 meter — selisihnya kurang dari 0,001. Artinya, kalau mutu sebuah citra dinilai hanya dari nilai rata-ratanya, semua ukuran piksel tampak sama baiknya. Yang runtuh adalah **sebarannya**: rentang antarpersentil menyempit dari 0,414 menjadi 0,195, yaitu menyusut 53 persen. Informasi tidak hilang dari rerata; ia hilang dari keragaman.

Temuan kedua, dan yang menjelaskan mengapa hal itu penting. Untuk mengetahui mekanismenya, diukur jarak spektral ternormalisasi dari setiap piksel ke endmember terdekat (Tabel 6.8). Endmember yang dipakai adalah kelima varietas dari SpecLib [15].

Tabel 6.8 Jarak spektral ternormalisasi ke endmember terdekat, menurut ukuran piksel.

GSD (m)	Jarak minimum	Jarak p5	Jarak median	Piksel < 0,10	Piksel < 0,20
2	0,0133	0,1437	0,2386	0,51 %	26,27 %
10	0,0393	0,1576	0,2430	0,10 %	21,63 %
30	0,0987	0,1712	0,2486	0,01 %	16,06 %
100	0,1501	0,1885	0,2596	0,00 %	8,86 %
250	0,1750	0,2070	0,2660	0,00 %	3,89 %

Perhatikan pola yang muncul. **Jarak minimum memburuk 13 kali lipat** — dari 0,0133 pada 2 meter menjadi 0,1750 pada 250 meter. **Jarak median hampir tidak berubah** — 0,2386 menjadi 0,2660, naik hanya 11

persen. Sementara itu, **piksel yang cukup dekat ke endmember (jarak di bawah 0,20) menyusut dari 26,3 persen menjadi 3,9 persen**, berkurang 85 persen. Piksel dengan jarak di bawah 0,10 praktis **punah** di atas 20 meter.

Dengan kata lain, penggabungan piksel tidak menghancurkan spektrum rata-rata. Yang dihancurkannya adalah **ekor sebaran** — segelintir piksel yang cukup murni untuk mendekati spektrum varietas sebenarnya. Dan justru piksel-piksel itulah yang dibutuhkan penguraian spektral linear: tanpa piksel murni, tidak ada titik tambat untuk menetapkan skala fraksi, dan setiap piksel menjadi campuran tanpa acuan. Inilah alasan teknis mengapa resolusi spasial menentukan bagi LSU, dan bukan sekadar soal ketajaman tampilan.

Temuan ketiga, mengenai ambang petak. Petak sawah di Jawa umumnya berukuran 0,1 sampai 1 hektar, dengan sisi 32 sampai 100 meter. Pada Tabel 6.9 ditunjukkan berapa piksel yang dimiliki sebuah petak pada setiap ukuran piksel.

Tabel 6.9 Jumlah piksel per petak sawah menurut ukuran piksel.

GSD	Petak 32 m (0,1 ha)	Petak 50 m (0,25 ha)	Petak 100 m (1 ha)
2 m	256 piksel	625 piksel	2.500 piksel
10 m	10,2 piksel	25,0 piksel	100,0 piksel
30 m	1,1 piksel	2,8 piksel	11,1 piksel
250 m	0,0 piksel	0,0 piksel	0,2 piksel

Pada 30 meter, petak seluas 0,1 hektar hanya menempati **1,1 piksel**, dan petak 0,25 hektar hanya **2,8 piksel**. Artinya pada ukuran piksel itu sebuah petak sawah **bukan lagi objek yang terpisah** — ia menjadi sebagian kecil dari satu piksel bersama tetangganya. Pada 250 meter, bahkan petak satu hektar pun hanya 0,2 piksel. Angka-angka ini memberi dasar kuantitatif bagi pernyataan pada 6.8 bahwa 30 meter "sering sudah terlambat": bukan karena 30 meter terlalu kasar untuk melihat sawah, melainkan karena pada ukuran itu **satu petak tidak lagi utuh di dalam satu piksel**.

Perlu ditegaskan bahwa angka pada tabel-tabel di atas **tidak boleh digeneralisasi**. Besarnya bergantung pada keragaman tutupan di lokasi itu,

dan pengujian ini hanya memakai satu adegan, satu tanggal, satu lokasi. Yang dapat disimpulkan adalah **arah dan mekanismenya** — bahwa kehilangan informasi akibat piksel yang membesar terpusat pada ekor piksel murni, bukan pada rerata. Untuk mendapat angka yang berlaku umum, pengujian serupa perlu diulang pada beberapa lokasi dan musim.

Ada pula dua batasan yang perlu dinyatakan terbuka. **Pertama**, GSD kasar di sini dibuat secara sintetis dengan penggabungan blok dari citra 2 meter; cara ini tidak menirukan seluruh perilaku sensor kasar (tidak ada fungsi sebaran titik instrumen, tidak ada derau sensor, tidak ada perbedaan geometri tampilan), sehingga yang diuji adalah pengaruh ukuran piksel, bukan seluruh perilaku sensor. **Kedua**, pengukuran ini **tidak** mengukur akurasi pemetaan varietas, karena tidak ada kebenaran lapangan varietas pada adegan ini. Yang diukur adalah detail spasial dan ketersediaan piksel murni — dua prasyarat bagi pemisahan varietas, bukan hasil akhirnya.

6.9 Memilih scene Sentinel-2: awan, SCL, dan harmonisasi baseline

Pemilihan sensor baru separuh pekerjaan. Separuh lainnya adalah memilih **scene** yang benar-benar dapat dipakai, dan di sini tiga hal perlu diperiksa.

Yang pertama adalah **persentase tutupan awan**. Katalog Sentinel-2 mencantumkan angka tutupan awan untuk setiap scene, dan angka itu adalah penyaring pertama yang wajar: scene dengan tutupan awan tinggi tidak layak. Tetapi angka katalog tidak boleh dipercaya begitu saja. Ia dihitung untuk seluruh scene, sedangkan yang menarik bagi kita hanyalah area kajian. Sebuah scene dapat tercatat berawan rendah secara keseluruhan tetapi justru tertutup awan tepat di atas sawah yang ingin diamati. Karena itu angka katalog harus selalu diverifikasi pada area kajian sendiri.

Yang kedua adalah **Scene Classification Layer**. Kanal ini memberi setiap piksel satu kelas: vegetasi, tanah, air, awan, bayangan awan, salju, dan seterusnya. Dengan memeriksa SCL, kita tidak hanya tahu berapa persen piksel tertutup awan, tetapi juga **di mana** awan itu berada, dan apakah bayangannya ikut menutupi sawah. Bayangan awan sering lebih berbahaya daripada awan itu sendiri, karena ia tidak menghalangi pandangan tetapi menurunkan kecerahan secara tidak merata — sebuah gangguan yang tidak selalu terlihat pada citra tetapi merusak nilai reflektansi. Pelajaran yang sudah disinggung pada 6.5 berlaku di sini: SCL

menyimpan kelas sebagai bilangan bulat, dan ia tidak boleh ikut dibagi 10.000 bersama kanal spektral, karena pembagian itu akan merusak nilai kelasnya.

Yang ketiga, dan paling mudah terlewat, adalah **harmonisasi baseline**. Sejak awal 2022, ESA mengubah cara Sentinel-2 menyimpan data melalui apa yang disebut *processing baseline* 04.00. Untuk mencegah nilai negatif pada piksel yang sangat gelap, sebuah **offset** dikurangkan dari nilai digital mentah. Akibatnya, scene yang diproses sebelum dan sesudah perubahan itu tidak berada pada skala yang sama: selisihnya tetap, tetapi cukup besar untuk merusak analisis bila kedua kelompok scene dicampur tanpa penyesuaian. Praktik yang benar adalah memeriksa *processing baseline* setiap scene, dan bila scene-scene itu berasal dari dua rezim berbeda, menerapkan penyesuaian offset sebelum keduanya digabungkan. Langkah ini tampak remeh, tetapi kesalahannya bersifat sistematis dan akan terbawa ke seluruh analisis berikutnya — persis seperti kesalahan kuantifikasi pada 5.5.

Satu catatan tambahan mengenai **komposit (composite)**. Untuk pekerjaan ini, beberapa scene digabungkan menjadi satu komposit pada jendela tanggal tertentu. Penggabungan itu membawa manfaat — menutup lubang akibat awan — tetapi juga membawa risiko: bila scene-scene yang digabung berasal dari fase tumbuh yang berbeda, komposit itu memuat campuran fase, dan asumsi model campuran linear menjadi rusak. Persoalan ini dibahas panjang pada Bab 7, dan temuannya adalah bahwa jendela tanggal yang dipakai pada analisis awal memang salah. Pelajarannya sederhana tetapi keras: komposit harus dibangun dari scene yang **sejenis fase**, bukan sekadar dari scene yang bebas awan.

6.10 Membaca hasil validasi Landsat 9 lebih dalam

Angka-angka pada 6.6 mudah dibaca sebagai daftar, tetapi maknanya perlu diurai, karena di situlah letak keterbukaan bab ini.

Korelasi **0,839** antara NDVI kedua sensor sering dianggap kurang memuaskan oleh pembaca yang terbiasa melihat angka di atas 0,9. Penilaian itu perlu dikoreksi. Korelasi lintas-sensor tidak dapat dibandingkan dengan korelasi antar-citra dari sensor yang sama. Kedua citra diambil oleh instrumen berbeda, pada waktu berbeda dalam satu hari, dengan geometri pengamatan yang berbeda, lebar kanal yang berbeda, dan

koreksi atmosfer yang berbeda pula. Setiap perbedaan itu menambah derau yang tidak dapat dihilangkan. Dengan 333.818 piksel, korelasi 0,839 sudah jauh di atas apa yang dapat dicapai oleh kebetulan, dan ia menunjukkan bahwa kedua sensor mengukur besaran yang sama — bukan dua hal yang kebetulan mirip.

Ukuran kedua adalah **bias median -0,0505**. Tanda negatif berarti NDVI Landsat 9 secara sistematis lebih tinggi daripada NDVI Sentinel-2, dengan selisih kira-kira 0,05. Perlu ditegaskan bahwa bias bukan berarti salah satu sensor rusak. Ia adalah perbedaan sistematis yang dapat dijelaskan: kanal merah Landsat lebih lebar daripada kanal merah Sentinel-2, sehingga ia mencampur sedikit bagian merah yang lebih panjang, dan pencampuran itu menaikkan nilai NDVI secara halus. Yang penting adalah **besarnya** bias itu kecil — 0,05 pada skala NDVI yang membentang dari nol sampai satu — dan **arahnya konsisten**, sehingga dapat dikoreksi bila diperlukan. Bila biasanya besar atau arahnya berubah-ubah, barulah ada alasan untuk curiga.

Ukuran ketiga adalah **regresi $S_2 = 0,890 \times L_9 + 0,003$** . Kemiringan 0,890 berarti ketika NDVI Landsat naik satu satuan, NDVI Sentinel-2 naik 0,89 satuan — sedikit kurang dari satu, konsisten dengan tanda bias di atas. Intersep 0,003 praktis nol, artinya tidak ada pergeseran yang tidak dapat dijelaskan. Bila intersepnya jauh dari nol, itu tanda bahwa salah satu sensor memiliki latar yang berbeda pada seluruh rentang, dan itu akan lebih mengkhawatirkan. Dengan kemiringan mendekati satu dan intersep mendekati nol, dapat dikatakan kedua sensor berada pada skala yang sama dengan perbedaan sistematis yang kecil.

Angka keempat, RMSE 0,1687, perlu dibaca bersama simpangan baku NDVI kedua sensor — 0,2627 dan 0,2787. RMSE yang besarnya sekitar enam puluh persen simpangan baku itu wajar untuk perbandingan lintas-sensor: sebagian besar keragaman yang diukur kedua sensor memang sama, dan sisanya adalah derau serta perbedaan sistematis yang sudah diuraikan di atas.

Yang paling meyakinkan dari seluruh pengujian ini sebenarnya bukan angka korelasinya, melainkan **kesepakatan masker padi**: presisi 90,1 persen, recall 98,1 persen, dan F1 93,9 persen. Masker ini dibangun hanya dari ambang (threshold) NDVI, tanpa melibatkan fenologi (phenology). Bahwa dua sensor berbeda menghasilkan masker yang

hampir sama berarti definisi "padi" yang dipakai kedua sensor memang konsisten. Dan yang menutup seluruh keraguan: hull yang kosong juga muncul pada Landsat, di ketiga bidang kanal, dengan angka nol persen yang sama persis. Sebuah kebetulan tidak dapat menghasilkan tiga kebetulan berturut-turut. Kesimpulannya jelas — data Sentinel-2 yang dipakai memang sah, dan temuan hull yang kosong bukan akibat sensor tertentu.

6.11 Alternatif sensor dan trade-off biaya-manfaat

Sentinel-2 bukan satu-satunya pilihan, dan sebuah buku yang lengkap perlu menyebutkan alternatifnya beserta harga yang harus dibayar.

Sebelum membahasnya, perlu disebutkan bahwa kanal red-edge juga sudah diuji khusus untuk **padi**, bukan hanya untuk tutupan lahan umum. Wu dan rekan merancang indeks vegetasi berbasis red-edge untuk pemetaan sawah menggunakan gabungan citra Sentinel-1, Sentinel-2, dan GF-6, dan melaporkan bahwa pemanfaatan kanal red-edge memperbaiki pemisahan sawah dari tanaman lain [10]. Kajian itu menangani pemisahan **sawah dari bukan sawah**, bukan pemisahan **antar-varietas padi** — dua persoalan yang berbeda tingkat kesulitannya. Tetapi arah temuannya sejalan dengan apa yang ditemukan pada pekerjaan ini: informasi yang membedakan sawah dari lingkungannya memang terkonsentrasi di daerah transisi merah–inframerah dekat, dan justru di daerah itulah kanal red-edge bekerja.

WorldView-2/3 adalah sensor komersial dengan delapan kanal pada resolusi yang sangat halus, termasuk satu kanal kuning yang, seperti ditunjukkan pada 6.3, menghasilkan jarak antar-varietas paling longgar — 0,3079, lebih dari dua kali jarak Sentinel-2. Secara spektral, sensor ini jelas lebih mampu. Harganya adalah persoalannya: data WorldView tidak bebas, biayanya dihitung per kilometer persegi, dan untuk area kajian seluas 76,6 kali 49,8 kilometer — sekitar 3.800 kilometer persegi — biaya itu menjadi besar. Selain itu, sensor ini tidak memiliki kanal red-edge sejati; keunggulannya berasal dari kanal kuning dan resolusi spasialnya yang halus, bukan dari tiga titik pengamatan red-edge. Untuk pekerjaan rutin laboratorium, keunggulannya tidak sebanding dengan biayanya, meskipun untuk studi kasus intensif pada petak terbatas ia layak dipertimbangkan.

Sejauh mana keunggulan resolusi itu bernilai, sekarang dapat dinyatakan dengan angka. Pada pengujian yang dilaporkan pada 6.8.1, 26,3 persen piksel pada 2 meter cukup dekat ke salah satu endmember untuk dipakai sebagai titik tambat penguraian. Pada 30 meter tinggal 16,1 persen, dan pada 250 meter tinggal 3,9 persen. Untuk pemisahan varietas — yang bergantung tepat pada ketersediaan piksel murni — perbedaan sebesar itu bersifat menentukan, bukan sekadar penyempurnaan. Dengan kata lain, keunggulan WorldView bukan terletak pada tampilannya yang lebih tajam, melainkan pada **tersedianya piksel yang benar-benar murni** dalam jumlah yang cukup. Bagi studi kasus intensif pada petak terbatas, inilah membenaran teknis untuk biayanya; bagi pemetaan wilayah luas, biaya per kilometer persegi tetap menjadikannya tidak praktis, dan membenaran itu tidak berlaku.

Perlu dicatat bahwa produk WorldView yang dipakai untuk pengujian di atas hanya memuat **empat kanal** (biru, hijau, merah, inframerah dekat), bukan delapan kanal yang sebenarnya tersedia. Karena itu pengujian tersebut **tidak** dapat menguji klaim bahwa kanal red-edge yang menentukan keberhasilan pemisahan varietas — klaim yang dibahas pada 6.2.1 dan ditinjau ulang pada Bab 15. Hanya produk delapan kanal yang dapat mengujinya, dan pengujian semacam itu belum dilaksanakan.

PlanetScope menawarkan sesuatu yang berbeda: resolusi sekitar tiga meter dengan frekuensi kunjungan harian, dan sejumlah besar satelit kecil dalam konstelasi. Keunggulan utamanya adalah **waktu** — ia dapat menangkap fase tumbuh dengan kerapatan temporal yang tidak dapat ditandingi Sentinel-2. Tetapi konstelasi dasarnya hanya memiliki empat kanal (biru, hijau, merah, inframerah dekat), dan empat kanal itu tidak memuat red-edge. Generasi yang lebih baru menambahkan kanal red-edge, tetapi cakupannya lebih terbatas dan datanya tetap komersial. Untuk pekerjaan ini, di mana red-edge justru menjadi penentu, PlanetScope lebih tepat dipakai sebagai pelengkap — misalnya untuk memantau fenologi — daripada sebagai sensor utama pemisahan varietas.

PRISMA dan EnMAP mewakili kelas yang sama sekali berbeda: **hiperspektral**. Kedua misi ini mengamati Bumi dalam ratusan kanal sempit yang berkesinambungan, bukan dalam beberapa kanal lebar. Bagi pekerjaan endmember, sensor seperti ini sangat menarik, karena ia dapat mengukur bentuk spektrum secara utuh — termasuk posisi tebing red-edge

— dan karena itu berpotensi mengatasi masalah variabilitas endmember yang dibahas pada Bab 4. Tetapi harganya juga nyata. Resolusi spasialnya kasar, sekitar 30 meter, sehingga masalah piksel tercampur pada petak sawah Indonesia kembali muncul. Cakupan ulangnya jarang, sehingga peluang mendapat scene bebas awan pada jendela pembungaan tipis. Volume datanya besar, sehingga pemrosesannya menuntut sumber daya komputasi yang lebih berat. Dan yang paling praktis: ketersediaannya tidak sebanding dengan Sentinel-2, yang mengamati area kajian ini setiap beberapa hari.

Dari perbandingan ini, satu kerangka sederhana dapat dirumuskan. Pemilihan sensor selalu merupakan kompromi antara empat hal: **resolusi spektral** (berapa banyak dan seberapa sempit kanal), **resolusi spasial** (seberapa halus piksel), **resolusi temporal** (seberapa sering kunjungan), dan **biaya**. Tidak ada sensor yang unggul pada keempatnya sekaligus. WorldView unggul pada spasial dan spektral tetapi mahal; PlanetScope unggul pada temporal tetapi miskin spektral; hiperspektral unggul pada spektral tetapi lemah pada spasial dan temporal; Sentinel-2 berada di tengah pada ketiganya dan — ini yang menentukan — **gratis**. Untuk pekerjaan rutin laboratorium yang harus dapat diulang tanpa bergantung pada anggaran, kombinasi "cukup baik pada tiga sumbu dan bebas biaya" itu lebih bernilai daripada keunggulan pada satu sumbu yang harus dibayar mahal.

6.12 Konsekuensi untuk pemilihan sensor

Dari seluruh pembahasan di bab ini, tiga kesimpulan dapat ditarik.

Pertama, untuk pemisahan varietas padi, Sentinel-2 adalah pilihan minimum yang memadai, dan Landsat tidak memadai. Alasannya bukan mutu radiometri Landsat, tetapi ketiadaan kanal red-edge dan penyusutan jarak antar-varietas menjadi separuh.

Kedua, untuk keperluan validasi (validation) lintas-sensor, Landsat justru sangat berguna. Kesepakatan NDVI yang mencapai korelasi 0,839 dan kesepakatan masker padi dengan F1 93,9 persen memberi keyakinan bahwa data Sentinel-2 yang dipakai memang sah. Validasi seperti ini sebaiknya menjadi kebiasaan, bukan pengecualian.

Ketiga, WorldView-2/3 memiliki jarak antar-varietas yang paling longgar (0,3079) karena memiliki kanal kuning yang juga sensitif terhadap

kondisi tanaman. Namun sensor ini komersial, sehingga penggunaannya bergantung pada ketersediaan dana. Untuk pekerjaan rutin laboratorium, Sentinel-2 sudah mencukupi untuk empat dari lima varietas.

Satu catatan penutup yang perlu disampaikan secara terbuka: seluruh perbandingan di bab ini didasarkan pada **proksi** — rasio singular dan jarak spektral — bukan pada pengujian citra nyata dari setiap sensor. Proksi itu konsisten dengan hasil pengujian yang sesungguhnya pada Bab 10, tetapi pembaca perlu mengetahui bahwa dasarnya adalah perhitungan geometri endmember, bukan perbandingan lapangan.

7.1 Mengapa bab ini bukan pelengkap

Pada Bab 4 diperkenalkan masalah **variabilitas endmember (endmember)**: spektrum satu jenis tanaman tidak tetap, melainkan berubah menurut umur, kadar air, dan kondisinya [9]. Untuk padi, perubahan ini sangat besar. Padi yang baru ditanam, padi yang sedang tumbuh cepat, dan padi yang siap panen memiliki spektrum yang sangat berbeda — perbedaannya bisa melebihi perbedaan antar-varietas (variety).

Akibatnya, bila citra yang dianalisis memuat padi pada berbagai fase tumbuh sekaligus, variasi fase itu akan menutupi perbedaan varietas yang ingin kita ukur. Menghilangkan pengaruh fase karena itu bukan pekerjaan pelengkap, melainkan pekerjaan yang menentukan apakah pemisahan varietas mungkin dilakukan sama sekali.

Bab ini menjelaskan bagaimana fase tumbuh ditentukan dari data satelit, dan bagaimana hasilnya dipakai untuk memilih jendela tanggal citra. Isi bab ini juga menjadi dasar bagi temuan penting pada Bab 11, di mana terungkap bahwa jendela tanggal yang dipakai pada analisis awal ternyata salah.

Ada satu alasan tambahan mengapa bab ini diletakkan sebelum bab-bab pelaksanaan. Perubahan spektrum karena umur tanaman tidak dapat dikoreksi setelah citra diambil. Ia hanya dapat dihindari, dan cara menghindarinya adalah memilih citra yang seluruh piksel padinya berada pada fase tumbuh yang kurang lebih sama. Karena itu bab ini bukan sekadar latar belakang teoretis, melainkan penentu pada tahap mana citra diambil. Kesalahan pada tahap ini tidak dapat ditambal oleh algoritme yang lebih baik di belakangnya — dan justru itulah yang akan terbukti pada Bab 11.

7.2 Konsep dasar fenologi dari satelit

Fenologi (phenology) adalah ilmu tentang waktu terjadinya peristiwa musiman pada makhluk hidup — kapan tanaman mulai tumbuh, kapan berbunga, kapan panen. Dalam penginderaan jauh, fenologi diamati tidak secara langsung pada satu tanaman, melainkan sebagai perubahan pola pada sekumpulan piksel. Yang diamati bukan "kapan tanaman ini

berbunga", melainkan "kapan daerah ini secara rata-rata mencapai puncak kehijauan".

Ada tiga titik waktu yang biasanya diambil dari kurva pertumbuhan tanaman:

Awal musim (season) (*start of season*) — saat indeks vegetasi mulai naik secara konsisten di atas nilai dasar. Pada padi, ini bertepatan dengan masa setelah tanam, ketika tanaman mulai tumbuh aktif.

Puncak musim (*peak of season*) — saat indeks vegetasi mencapai nilai tertinggi. Pada padi, ini bertepatan dengan masa pembungaan (*flowering*), ketika kanopi (*canopy*) sudah menutup penuh dan dedaunan paling rapat. Istilah *heading* dipakai dalam buku ini untuk merujuk pada titik ini.

Akhir musim (*end of season*) — saat indeks vegetasi turun kembali ke nilai dasar. Pada padi, ini bertepatan dengan masa pematangan dan panen.

Selain ketiganya, satu besaran lain yang penting adalah **durasi musim**, yaitu selisih antara awal dan akhir musim. Untuk padi Indonesia, durasi ini berkisar 90 sampai 120 hari tergantung varietasnya.

7.2.1 Siklus tumbuh padi Indonesia dan lama setiap fase

Untuk memahami mengapa kurva indeks vegetasi padi berbentuk seperti yang teramati, perlu diketahui terlebih dahulu bagaimana padi tumbuh sebenarnya. Siklus hidup padi sawah di Indonesia berjalan melalui empat tahap besar yang berurutan, dan setiap tahap meninggalkan jejak yang berbeda pada kanopi — sehingga meninggalkan jejak yang berbeda pula pada kurva indeks vegetasi.

Tahap pertama adalah **persemaian**. Benih disemai di petak kecil (*bedengan* persemaian) selama kurang lebih 15 sampai 25 hari sebelum dipindahkan ke petak produksi. Pada tahap ini tanaman masih rapat dan pendek, kanopinya belum menutup tanah, dan sebagian besar permukaan petak masih berupa air atau tanah terbuka. Dalam citra resolusi kasar seperti MODIS, tahap persemaian nyaris tidak terlihat sebagai vegetasi; yang terekam justru genangan (*inundation*) air di petak produksi yang sedang dipersiapkan. Karena itu fase persemaian justru lebih banyak terdeteksi melalui indeks genangan daripada melalui indeks kehijauan —

sebuah kenyataan yang menjadi dasar pemilihan NDFI, sebagaimana dibahas pada 6.4.

Tahap kedua adalah **vegetatif**, yang dimulai sejak bibit dipindahkan ke petak produksi hingga tanaman mulai membentuk organ generatif. Fase ini berlangsung sekitar 30 sampai 45 hari. Pada awal fase vegetatif, tanaman masih kecil dan permukaan air masih mendominasi; indeks vegetasi berada pada titik terendahnya. Seiring berjalannya waktu, tanaman tumbuh cepat, jumlah anakan bertambah, dan kanopi mulai menutup. Pada akhir fase vegetatif, kanopi sudah menutup hampir penuh dan indeks vegetasi naik tajam. Inilah periode kenaikan paling curam pada kurva EVI, dan inilah sebabnya kenaikan yang konsisten setelah titik minimum menjadi salah satu kriteria agronomis pada PhenoRice.

Tahap ketiga adalah **generatif**, yang mencakup masa pembentukan malai hingga pembungaan (*heading*). Fase ini berlangsung sekitar 25 sampai 35 hari. Pada lembar fakta, panjang fase generatif yang terukur dari data memiliki nilai tengah **29 hari**. Pada fase ini kanopi mencapai kerapatan maksimum, dan indeks vegetasi mencapai puncaknya. Puncak kurva EVI inilah yang diterjemahkan sebagai tanggal pembungaan. Karena kanopi pada fase ini sangat rapat, indeks vegetasi yang dipakai harus tetap peka pada biomassa tinggi — dan inilah alasan utama EVI dipilih ketimbang NDVI, sebagaimana diuraikan pada 6.3.

Tahap keempat adalah **pematangan**, yang berlangsung sejak pembungaan selesai hingga panen, sekitar 30 sampai 40 hari. Pada fase ini daun mulai menguning dan mengering, kanopi membuka kembali, dan indeks vegetasi turun tajam. Penurunan yang cepat pada akhir kurva inilah yang menjadi salah satu kriteria pada PhenoRice: sebuah puncak baru dianggap sah bila diikuti penurunan yang cepat akibat pematangan dan panen.

Bila keempat tahap itu dijumlahkan, rentangnya kira-kira 100 sampai 145 hari dari semai hingga panen, dengan masa di petak produksi (setelah persemaian) sekitar 90 sampai 120 hari. Angka ini konsisten dengan durasi musim yang terukur dari data pada bab ini, yaitu **92 hari** (persentil (percentile) 25 sebesar 79 hari dan persentil 75 sebesar 110 hari). Kesamaan rentang itu bukan kebetulan, melainkan bukti tidak langsung bahwa kurva yang tertangkap memang kurva pertumbuhan padi.

Satu hal yang perlu ditegaskan mengenai variasi antar-varietas. Umur padi bervariasi menurut varietas: varietas genjah dapat dipanen pada sekitar 90 sampai 105 hari, sedangkan varietas berumur lebih panjang mencapai 110 sampai 125 hari. Karena pemisahan varietas adalah tujuan buku ini, perbedaan umur itu sendiri menjadi salah satu petunjuk. Namun pada tahap fenologi ini, yang dimanfaatkan bukan perbedaan umurnya, melainkan kesamaan rentangnya: seluruh varietas yang kita pelajari berada di dalam rentang 60 sampai 150 hari, sehingga penyaringan durasi musim yang dipakai pada 7.6 dapat menerima semuanya sekaligus menolak tanaman dengan pola umur yang jauh berbeda.

7.2.2 Mengapa dua musim tanam per tahun terjadi di Indramayu

Daerah kajian terletak di dataran pantai utara Jawa Barat, di Kabupaten Indramayu dan sekitarnya. Daerah ini termasuk lumbung padi utama Jawa Barat, dan pola tanamnya berbeda dari daerah beriklim monsun yang hanya memiliki satu musim hujan tegas. Di Indramayu, dua musim tanam (cropping season) padi dalam satu tahun adalah hal yang lazim, dan pemahaman atas sebabnya penting karena pola itu langsung terlihat pada sebaran tanggal pembungaan yang diukur pada bab ini.

Musim tanam pertama umumnya jatuh pada awal musim hujan, ketika curah hujan mulai cukup untuk mengisi saluran irigasi dan petak sawah tanpa bergantung sepenuhnya pada pompa. Musim tanam kedua menyusul setelah panen pertama, dan pada musim ini ketersediaan air sangat bergantung pada **irigasi berkelanjutan** dari jaringan saluran, bukan pada hujan. Karena itu, di daerah dengan jaringan irigasi yang baik seperti dataran pantai utara Jawa, penanaman musim kedua dimungkinkan meskipun curah hujan sudah berkurang.

Keberadaan dua musim tanam ini membawa tiga implikasi yang langsung menyentuh pekerjaan pemetaan varietas.

Implikasi pertama, deret waktu (time series) harus cukup panjang. Karena satu tahun memuat dua musim, sebuah deret waktu yang hanya mencakup beberapa bulan tidak akan memuat pola lengkap. Sebaliknya, deret yang mencakup dua tahun justru memuat dua hingga empat musim — dan hal ini, sebagaimana akan dibahas pada 7.6, menimbulkan masalah tersendiri ketika awal dan akhir musim dihitung dari seluruh deret.

Implikasi kedua, penanaman tidak serentak. Meskipun secara umum ada dua musim, waktu tanam yang tepat bergeser dari satu petak ke petak lain mengikuti jadwal pengairan. Pada sistem irigasi bergilir (rotational irrigation), air dialirkan ke blok-blok petak secara bergantian, sehingga satu blok mulai tanam beberapa pekan lebih awal atau lebih lambat daripada blok lain. Akibatnya, sebaran tanggal pembungaan tidak berupa satu puncak sempit, melainkan satu puncak besar dengan beberapa kelompok kecil di sekitarnya. Persis inilah pola yang teramati pada data Indramayu, dan tafsirannya dibahas pada 6.8.1.

Implikasi ketiga, pemilihan jendela citra menjadi kritis. Karena fase tumbuh bergeser antar-petak, satu citra tunggal tidak akan pernah memuat seluruh sawah pada fase yang sama. Yang dapat dilakukan hanyalah memilih jendela yang memuat fase terbanyak — yaitu jendela di sekitar puncak pembungaan, ketika paling banyak petak berada pada fase yang sama. Selebihnya adalah kompromi, dan kompromi itu perlu dilaporkan secara terbuka, sebagaimana dilakukan pada 7.8 dan 6.9.

7.3 EVI dan mengapa lebih baik daripada NDVI

Indeks vegetasi yang dipakai untuk fenologi dalam pekerjaan ini adalah **EVI** (*Enhanced Vegetation Index*), bukan NDVI.

Alasannya bersifat teknis dan penting. NDVI dihitung dari kanal (band) merah dan inframerah dekat. Pada tanaman dengan biomassa rendah, NDVI bekerja baik. Tetapi ketika biomassa menjadi tinggi — kanopi sangat rapat, seperti padi pada fase puncak — NDVI mengalami **kejenuhan**: nilainya mendekati batas atas dan berhenti berubah meskipun biomassa masih bertambah.

Huete dan rekan menunjukkan hal ini secara eksplisit: NDVI mengalami kejenuhan asimtotik pada daerah berbiomassa tinggi, sedangkan EVI tetap peka terhadap variasi kanopi [5]. Karena justru fase puncak yang menjadi acuan dalam pekerjaan ini, kejenuhan NDVI akan membuat puncak itu sulit ditentukan dengan tepat.

EVI mengatasi kejenuhan melalui tiga penyesuaian: ia menambahkan faktor penyesuaian latar kanopi, memasukkan kanal biru untuk mengoreksi pengaruh aerosol, dan menerapkan faktor penguatan. Konfigurasi koefisien yang dipakai MODIS adalah $L=1$, $C1=6$, $C2=7,5$, dan $G=2,5$ [5].

Secara bentuk, EVI dapat dituliskan sebagai rasio yang memuat kanal inframerah dekat, merah, dan biru, dengan penyebut yang disesuaikan agar tidak pernah menjadi nol. Kanal biru dipakai karena aerosol atmosfer paling kuat memengaruhi panjang gelombang pendek; dengan mengurangi pengaruh biru secara terkendali, sisa pengaruh aerosol pada kanal merah dapat ditekan. Faktor L adalah penyesuaian latar kanopi: bila nilainya satu, istilah penyebut tidak terlalu bergantung pada kecerahan latar, sehingga tanah terbuka atau air yang berada di bawah kanopi tidak lagi mendorong indeks ke nilai rendah secara berlebihan. Faktor G adalah penguatan yang mengembalikan nilai EVI ke rentang yang sebanding dengan NDVI, sehingga ambang (threshold)-ambang yang biasa dipakai untuk NDVI dapat diterjemahkan dengan mudah.

7.3.1 Mengapa kejenuhan NDVI merugikan penentuan puncak


Kejenuhan bukan sekadar ketidaknyamanan estetik; ia merusak justru besaran yang paling kita butuhkan. Ketika NDVI sudah mendekati batas atas, kenaikan biomassa selanjutnya tidak lagi mengubah nilai indeks. Akibatnya, kurva NDVI di sekitar puncak menjadi **datar**. Pada kurva yang datar, menentukan satu titik sebagai "puncak" menjadi tidak pasti: titik tertinggi dapat jatuh pada salah satu dari beberapa observasi yang nilainya nyaris sama, dan pergeseran kecil pada derau (noise) dapat memindahkan tanggal puncak beberapa selang waktu. Karena tanggal puncak inilah yang dipakai untuk memilih jendela citra, ketidakpastian itu merambat langsung ke kesalahan jendela.

EVI, dengan penyebut yang tetap berubah seiring biomassa, mempertahankan kemiringan kurva di sekitar puncak. Kurva yang tetap melengkung memungkinkan puncak ditentukan dengan galat yang lebih kecil, dan dengan demikian tanggal pembungaan yang dipakai untuk menetapkan jendela citra menjadi lebih dapat dipercaya.

7.4 NDFI: mendeteksi genangan sebagai penanda sawah

Ada satu ciri yang membedakan sawah dari tanaman lain, dan ciri itu tidak terlihat pada indeks vegetasi: **sawah digenangi air pada awal musim tanam**. Permukaan yang tergenang memantulkan sedikit cahaya pada inframerah gelombang pendek (shortwave infrared), sehingga dapat dikenali dari perbandingan antara inframerah dekat dan inframerah gelombang pendek.

Indeks yang dipakai untuk ini adalah **NDFI** (*Normalized Difference Flooding Index*), dihitung dari kanal inframerah dekat dan inframerah gelombang pendek.



Gambar 7.1. Nilai genangan maksimum (NDFI). Sawah selalu memperlihatkan genangan pada awal musim tanam, sedangkan tanaman lain tidak.

Pendekatan ini menjadi bagian inti dari algoritme PhenoRice yang dikembangkan Boschetti dan rekan, yang mendeteksi sawah melalui kombinasi antara **genangan yang terdeteksi lebih dahulu, diikuti pertumbuhan vegetasi yang cepat** [4].

Prinsipnya sederhana tetapi kuat. Tanaman lain bisa saja memiliki kurva kehijauan yang mirip padi. Tetapi hanya sawah yang memiliki pola **genangan lalu tumbuh**. Dengan memeriksa keberadaan genangan sebelum pertumbuhan, sejumlah besar kekeliruan dapat dihindari.

7.4.1 Mengapa NDFI bekerja secara fisis

NDFI bekerja karena air dan vegetasi berperilaku berlawanan pada dua panjang gelombang yang dipakai. Untuk memahami mengapa demikian, perlu ditinjau perilaku cahaya pada kedua kanal tersebut.

Kanal **inframerah dekat** (sekitar 0,86 mikrometer pada MODIS) memiliki sifat yang khas: air menyerapnya sangat kuat, sedangkan daun sehat memantulkannya sangat kuat. Karena itu, pada permukaan yang tergenang, inframerah dekat yang terpantul ke sensor menjadi rendah;


sebaliknya, pada kanopi daun yang rapat, inframerah dekat yang terpantul menjadi tinggi.

Kanal **inframerah gelombang pendek** (sekitar 1,6 atau 2,1 mikrometer) memiliki sifat yang berlawanan untuk air: air menyerapnya bahkan lebih kuat lagi, sedangkan tanah dan vegetasi kering memantulkannya cukup kuat. Artinya, pada permukaan yang tergenang, kedua kanal sama-sama rendah; pada kanopi vegetasi yang rapat, keduanya sama-sama tinggi. Bila hanya itu yang terjadi, perbandingan keduanya tidak akan memberi informasi tambahan.

Yang membuat NDFI bekerja adalah perbedaan **laju** perubahan keduanya terhadap kondisi permukaan. Ketika air mulai menggenangi petak, inframerah gelombang pendek turun lebih tajam daripada inframerah dekat, karena air menyerapnya lebih kuat. Akibatnya, selisih antara keduanya berubah secara sistematis: pada permukaan tergenang, nilai inframerah dekat menjadi relatif lebih tinggi dibandingkan inframerah gelombang pendek daripada yang seharusnya. Perbandingan ternormalisasi antara keduanya — yaitu NDFI — menangkap perubahan selisih itu.

Dengan kata lain, NDFI tidak sekadar mengukur "apakah ada air", melainkan mengukur **seberapa basah permukaan** melalui pergeseran keseimbangan kedua kanal. Pada sawah yang baru digenangi, NDFI naik tinggi; pada sawah yang sudah ditanami dan airnya surut, NDFI turun kembali; pada tanah kering, NDFI rendah. Karena itu NDFI dapat membedakan genangan sawah dari sekadar tanah lembap.

Satu catatan penting mengenai keterbatasan fisisnya: genangan di bawah kanopi yang sudah rapat tidak dapat terdeteksi, karena kanopi menutupi air di bawahnya. Karena itu NDFI hanya berguna pada **awal musim**, sebelum kanopi menutup — dan justru itulah posisi yang dibutuhkan PhenoRice: bukti genangan dicari **sebelum** kenaikan EVI, bukan bersamaan dengan puncaknya. Kedua indeks saling melengkapi menurut waktu: NDFI berperan pada awal, EVI berperan pada puncak.



Gambar 7.2. Nilai puncak EVI per piksel, yang bertepatan dengan fase pembungaan.

7.5 Algoritme PhenoRice dan pelajarannya

Algoritme PhenoRice yang dirumuskan Boschetti dan rekan adalah acuan penting untuk pekerjaan ini [4]. Ia bekerja dengan aturan yang dapat dirangkum sebagai berikut.

Pertama, deret waktu EVI dihaluskan menggunakan tapis Savitzky–Golay dua iterasi, dengan pembobotan menurut mutu data. Tujuannya mengurangi derau akibat tutupan awan dan variasi sudut pengambilan.

Kedua, seluruh nilai minimum dan maksimum lokal pada kurva yang sudah dihaluskan diidentifikasi. Setiap pasangan minimum–maksimum kemudian diuji terhadap sejumlah kriteria agronomis, antara lain: selang waktu antara keduanya harus berada dalam rentang yang sesuai dengan umur varietas padi di daerah tersebut; kondisi meteorologis saat minimum harus memungkinkan (suhu permukaan di atas ambang); nilai EVI saat minimum harus cukup rendah; harus ada bukti genangan di sekitar waktu itu; harus ada kenaikan EVI yang konsisten setelahnya; dan maksimum harus diikuti penurunan EVI yang cepat akibat pematangan dan panen.

Ketiga, piksel yang memenuhi seluruh kriteria ditandai sebagai padi, dan tanggal awal musim serta tanggal pembungaannya dihitung. Algoritme ini juga dapat mendeteksi beberapa musim tanam dalam satu deret waktu, dengan membagi deret itu menjadi beberapa periode.

Pengujian PhenoRice pada tiga wilayah dengan karakter berbeda — sistem padi–bera (fallow) di Italia, padi–tanaman lain di India, dan padi–padi di Filipina — menunjukkan hasil yang konsisten, dengan koefisien determinasi antara 0,75 dan 0,92, dan tanggal awal musim yang sangat dekat dengan data acuan ($r^2=0,98$, galat absolut rata-rata 9,95 hari) [4].

Pelajaran yang diambil dari algoritme ini untuk pekerjaan kita ada dua. **Pertama**, kombinasi antara indeks genangan dan indeks vegetasi jauh lebih andal daripada indeks vegetasi saja. **Kedua**, kriteria agronomis — seperti rentang durasi musim yang wajar — merupakan penyaring yang kuat, karena kriteria itu menyingkirkan piksel yang secara spektral tampak seperti padi tetapi secara agronomis tidak masuk akal.

7.5.1 Mengapa setiap kriteria agronomis ada

Kekuatan PhenoRice bukan terletak pada salah satu kriterianya, melainkan pada gabungan seluruhnya. Setiap kriteria menutup satu jenis kekeliruan yang tidak dapat ditutup oleh kriteria lain. Karena itu perlu dipahami mengapa masing-masing ada.

Kriteria **rentang durasi musim** menutup kekeliruan yang paling umum: tanaman lain yang kurva kehijaunnya mirip padi tetapi umurnya berbeda. Pohon memiliki musim yang jauh lebih panjang; tanaman semusim pendek memiliki musim yang jauh lebih singkat. Dengan menuntut durasi berada di dalam rentang umur padi, sebagian besar tanaman lain langsung tersingkir.

Kriteria **suhu permukaan saat minimum** menutup kekeliruan pada daerah dan waktu yang secara agronomis tidak mungkin ditanami padi. Padi memerlukan suhu di atas ambang tertentu untuk dapat tumbuh; wilayah yang terlalu dingin pada saat kurva minimum tidak mungkin merupakan awal musim tanam padi, betapapun miripnya bentuk kurvanya.

Kriteria **nilai EVI saat minimum harus cukup rendah** menutup kekeliruan berupa puncak semu: kenaikan kecil pada kurva yang sudah tinggi dapat tampak sebagai "musim" padahal hanya variasi biasa. Dengan menuntut titik minimum yang benar-benar rendah, musim yang dianggap sah adalah musim yang benar-benar dimulai dari kondisi tanaman belum tumbuh.

Kriteria **bukti genangan di sekitar waktu itu** menutup kekeliruan paling penting, yaitu tanaman non-sawah yang bervegetasi rapat. Inilah

kriteria yang membedakan PhenoRice dari sekadar analisis kurva kehijauan, karena hanya sawah yang memiliki pola genangan sebelum tumbuh.

Kriteria **kenaikan EVI yang konsisten setelah minimum** menutup kekeliruan berupa fluktuasi derau. Derau dari tutupan awan atau sudut pengambilan dapat menciptakan lonjakan sesaat yang tampak seperti awal musim; dengan menuntut kenaikan yang berlanjut, lonjakan sesaat tersingkir.

Kriteria **penurunan cepat setelah maksimum** menutup kekeliruan berupa tanaman menetap. Tanaman tahunan yang tetap hijau sepanjang tahun tidak mengalami penurunan tajam setelah puncak; dengan menuntut penurunan akibat pematangan dan panen, sawah terpisah dari tanaman menetap.

Perhatikan bahwa tidak ada satu pun kriteria yang cukup sendiri. Sebuah kurva dapat memenuhi kriteria durasi tetapi berasal dari tanaman lain; sebuah kurva dapat memiliki genangan tetapi tanpa kenaikan yang konsisten. Yang membuat PhenoRice bekerja adalah **irisan** seluruh kriteria, bukan salah satunya. Prinsip ini sejalan dengan pelajaran Bab 8, di mana irisan masker (mask) yang longgar justru lebih buruk daripada gabungan — tetapi di sini irisannya berbeda: yang diiriskan adalah kriteria yang **saling menutup kekeliruan**, bukan dua metode yang menangkap hal yang sama.

7.5.2 Tapis Savitzky–Golay: mengapa jendela 7 dan orde 2

Bagian pertama PhenoRice adalah penghalusan deret waktu dengan tapis Savitzky–Golay. Tapis ini dipilih karena ia menghaluskan derau tanpa menggeser posisi puncak — sesuatu yang tidak dapat dilakukan oleh tapis rerata bergerak biasa, yang selalu meratakan dan menggeser puncak ke bawah.

Secara matematis, tapis Savitzky–Golay bekerja dengan memasang sebuah polinomial berderajat rendah pada sejumlah titik data di sekitar setiap titik, lalu mengambil nilai polinomial itu sebagai nilai halus di titik tersebut. Untuk setiap titik, ia menyelesaikan pencocokan kuadrat terkecil sebuah polinomial berderajat tertentu terhadap sejumlah titik di dalam jendela, kemudian mengevaluasi polinomial itu di pusat jendela. Karena seluruh titik di dalam jendela ikut menentukan nilai di pusat, derau acak

saling meniadakan, sementara bentuk kurva — termasuk posisi dan ketinggian puncak — dipertahankan.

Dua parameter menentukan perilakunya: **panjang jendela** dan **orde polinomial**. Pada pekerjaan ini jendela yang dipakai berjumlah tujuh titik, dan ordenya dua.

Mengapa **jendela tujuh titik**? Panjang jendela menentukan seberapa banyak derau yang dihaluskan dan seberapa halus kurva yang dihasilkan. Jendela yang terlalu lebar akan meratakan puncak dan menggeser tanggal pembungaan, sehingga jendela citra yang ditetapkan dari puncak itu menjadi salah. Jendela yang terlalu sempit tidak menghaluskan apa pun — derau lolos utuh dan puncak semu dapat muncul, sehingga piksel yang bukan padi ikut diterima. Dengan selang observasi 16 hari, jendela tujuh titik mencakup sekitar 112 hari, yaitu kira-kira satu musim tanam padi. Rentang itu cukup lebar untuk menekan derau, tetapi tidak lebih lebar dari satu musim sehingga tidak mencampur dua musim yang berdekatan. Inilah pertimbangan yang menjadikan tujuh titik sebagai pilihan yang masuk akal untuk data MOD13Q1.

Mengapa **orde dua**? Orde polinomial menentukan seberapa rumit bentuk yang dapat diikuti tapis. Orde nol hanya menghitung rata-rata dan akan meratakan puncak. Orde satu cocok untuk kecenderungan garis lurus, tetapi tidak dapat mengikuti kelengkungan puncak, sehingga puncak akan terpotong. Orde dua — yaitu parabola — dapat mengikuti naik, puncak, dan turun sekaligus, sehingga bentuk kurva pertumbuhan padi yang melengkung dapat dipertahankan. Orde yang lebih tinggi dari dua akan mulai mengikuti derau, karena polinomial berderajat tinggi dapat menyesuaikan diri dengan fluktuasi acak; derau justru lolos kembali. Orde dua adalah titik seimbang: cukup lentur untuk mengikuti bentuk pertumbuhan, tetapi cukup kaku untuk tidak mengejar derau.

Singkatnya, jendela tujuh titik mengatur **seberapa banyak** yang dihaluskan, sedangkan orde dua mengatur **bentuk seperti apa** yang dipertahankan. Keduanya dipilih agar puncak tetap pada tempatnya, karena dari tempat puncak itulah seluruh penentuan jendela citra bergantung.

7.6 Pelaksanaan pada data Indramayu

Untuk pekerjaan ini, data yang dipakai adalah produk MODIS MOD13Q1 pada resolusi 250 meter dan selang waktu 16 hari. Data

diunduh melalui Google Earth Engine untuk periode 14 September 2025 sampai 29 Agustus 2026, menghasilkan 23 observasi.

Dari setiap piksel, dua besaran dihitung: EVI dan NDFI. Sebelum dipakai, mutu data disaring menggunakan kanal *DetailedQA*, khususnya dua bit pertama yang menyatakan mutu indeks vegetasi. Hanya observasi dengan mutu baik atau marjinal yang dipertahankan. Hasilnya sekitar 52 persen observasi lolos penyaringan — sebuah angka yang wajar untuk daerah tropis dengan tutupan awan tinggi.

Setiap deret waktu yang lolos kemudian dihaluskan, dan puncaknya ditentukan. Perlu dicatat bahwa deret waktu yang dipakai mencakup **dua tahun**, sehingga memuat dua musim tanam. Bila awal dan akhir musim dihitung dari seluruh deret, hasilnya menjadi tidak bermakna — durasinya bisa mencapai lebih dari 700 hari, dan seluruh piksel akan gugur pada penyaringan. Karena itu pencarian awal dan akhir musim dibatasi pada jendela 150 hari di sekitar puncak yang terdeteksi.

Piksel kemudian diterima sebagai padi bila memenuhi tiga syarat sekaligus: puncak EVI minimal 0,35; durasi musim antara 60 dan 150 hari; dan terdapat bukti genangan dengan NDFI maksimum minimal 0,10.

7.6.1 Kanal *DetailedQA* MOD13Q1 bit per bit

Mutu data MOD13Q1 disampaikan melalui kanal *DetailedQA*, yang menyimpan sejumlah keterangan mutu dalam bentuk **bit-bit** pada satu bilangan bulat. Setiap bit atau kelompok bit menempati posisi tertentu, dan maknanya ditentukan oleh posisi itu. Memahami susunan bit ini penting karena penyaringan mutu yang salah akan membuang observasi yang sebenarnya baik, atau sebaliknya meloloskan observasi yang buruk — dan keduanya merusak kurva fenologi.

Secara umum, kanal *DetailedQA* pada MOD13Q1 menyusun keterangan sebagai berikut. Dua bit **paling rendah** (bit 0–1) menyatakan mutu indeks vegetasi secara keseluruhan, dengan tingkat: baik, marjinal, buruk, dan tidak dapat dipakai. Dua bit berikutnya (bit 2–3) menyatakan mutu kanal inframerah dekat, dengan tingkat baik, marjinal, buruk, dan tidak dipakai. Dua bit berikutnya lagi menyatakan mutu kanal merah. Setelah itu terdapat bit-bit untuk keterangan tambahan, seperti tingkat aerosol, keberadaan awan yang berdekatan, kemungkinan bayangan, dan sebagainya.

Yang dipakai pada pekerjaan ini adalah **dua bit pertama**, yaitu mutu indeks vegetasi keseluruhan. Cara membacanya adalah dengan mengambil bilangan bulat DetailedQA, lalu melakukan operasi bitwise AND dengan tiga (yaitu dua bit yang menyala), sehingga tersisa hanya dua bit pertama:

$$\text{mutu} = \text{DetailedQA} \& 3$$

Nilai 0 berarti mutu baik, 1 berarti marjinal, 2 berarti buruk, dan 3 berarti tidak dapat dipakai. Observasi dengan nilai 0 dan 1 dipertahankan; nilai 2 dan 3 disingkirkan. Penyaringan inilah yang menyisakan sekitar 52 persen observasi.

Mengapa hanya dua bit pertama yang dipakai, bukan seluruh kanal QA? Karena bit-bit lain menyampaikan keterangan tentang kondisi yang **menyebabkan** mutu, bukan ringkasan mutunya sendiri. Ringkasan mutu indeks vegetasi sudah memperhitungkan kondisi-kondisi itu. Dengan memakai dua bit pertama, penyaringan menjadi sederhana dan konservatif: yang disingkirkan adalah observasi yang memang dinyatakan buruk untuk dipakai, sedangkan observasi yang hanya terpengaruh aerosol ringan tetap dipertahankan dan selebihnya diserahkan kepada penghalusan Savitzky–Golay. Pendekatan bertingkat ini — penyaringan bit untuk mutu kasar, penghalusan untuk derau sisa — menghindari pembuangan data yang berlebihan di daerah tropis, di mana tutupan awan yang tinggi membuat hampir setiap observasi sedikit terganggu.

Perlu ditegaskan bahwa operasi bitwise AND dengan tiga bukan pilihan sembarang; ia adalah cara memisahkan dua bit terendah dari bilangan bulat yang lebih panjang tanpa memengaruhi bit-bit di atasnya. Bila operasi ini dilakukan salah — misalnya dengan membaca bilangan bulat QA secara keseluruhan dan membandingkannya dengan ambang — penyaringan akan gagal, karena bilangan bulat penuh memuat banyak keterangan lain yang nilainya jauh lebih besar daripada tiga.

7.6.2 Mengapa pencarian awal dan akhir musim dibatasi 150 hari

Deret waktu pada pekerjaan ini mencakup 14 September 2025 sampai 29 Agustus 2026, yaitu sekitar 350 hari, dan memuat **dua** musim tanam. Hal ini menimbulkan masalah yang tidak tampak pada pandangan pertama.

Algoritme awal dan akhir musim bekerja dengan mencari titik minimum sebelum puncak dan titik minimum setelah puncak pada seluruh

deret. Bila deret memuat dua musim, maka titik minimum "setelah puncak" untuk musim pertama sebenarnya adalah titik minimum yang mendahului puncak musim kedua — bukan akhir musim pertama. Akibatnya, durasi yang dihitung bukan panjang satu musim, melainkan jarak antara puncak musim pertama dan titik minimum antara dua musim, atau bahkan jarak yang melintasi dua musim sekaligus. Pada kasus yang paling buruk, durasi yang dihitung dapat mencapai lebih dari 700 hari, jauh melampaui umur padi mana pun.

Konsekuensinya serius: penyaringan durasi musim (60 sampai 150 hari) akan **menolak seluruh piksel**, sehingga tidak ada satu pun piksel yang diterima sebagai padi. Ini bukan kegagalan algoritme, melainkan kesalahan pada penentuan ruang lingkup pencarian. Deret dua tahun harus diperlakukan sebagai dua deret satu musim, bukan sebagai satu deret panjang.

Solusinya adalah membatasi pencarian awal dan akhir musim pada **jendela 150 hari** di sekitar setiap puncak yang terdeteksi. Dengan jendela ini, pencarian titik minimum sebelum dan sesudah puncak tidak akan melampaui batas satu musim, karena 150 hari lebih panjang daripada umur padi terpanjang (sekitar 120 hari) tetapi lebih pendek daripada jarak dua musim penuh. Batas ini memberi ruang yang cukup untuk menemukan awal dan akhir musim yang sesungguhnya, sekaligus mencegah pencarian melompat ke musim berikutnya.

Angka 150 hari dipilih dengan pertimbangan yang dapat diperiksa. Batas bawahnya adalah umur padi terpanjang, sekitar 120 hari, sehingga jendela harus lebih panjang dari itu agar tidak memotong musim yang sah. Batas atasnya adalah jarak minimum antara dua puncak musim berurutan, yang pada pola dua musim per tahun berkisar sekitar 180 hari; jendela harus lebih pendek dari itu agar tidak mencampur dua musim. Rentang 120 sampai 180 hari menyisakan pilihan yang aman di sekitar 150 hari, yang cukup longgar terhadap batas bawah dan cukup longgar terhadap batas atas.


Prinsip umum yang dapat diambil dari sini: **setiap deret waktu multi-musim harus dipecah sebelum analisis fenologi dijalankan**. Membatasi jendela pencarian adalah cara paling sederhana untuk melakukan pemecahan itu tanpa harus memotong deret secara fisik — dan cara ini sekaligus menjaga agar satu piksel dapat menghasilkan beberapa

musim, sesuai kebutuhan algoritme PhenoRice untuk mendeteksi musim tanam berganda.


7.7 Hasil: bukti bahwa yang terdeteksi memang sawah

Hasil penyaringan memberikan bukti tidak langsung yang kuat bahwa kurva yang tertangkap memang kurva pertumbuhan padi.

Durasi musim yang terukur memiliki nilai tengah 92 hari, dengan persentil 25 sebesar 79 hari dan persentil 75 sebesar 110 hari. Rentang ini persis sesuai umur varietas padi Indonesia yang umumnya 90 sampai 120 hari. Bila yang tertangkap adalah tanaman lain, durasinya kemungkinan besar akan berbeda jauh — pohon memiliki musim yang lebih panjang, sedangkan tanaman semusim pendek memiliki musim yang lebih singkat.



Gambar 7.3. Durasi musim tanam per piksel, dalam hari.



Gambar 7.4. Panjang fase generatif per piksel, dalam hari.

Dari seluruh piksel yang memiliki kurva valid, sebanyak 59,5 persen lolos sebagai padi. Sisanya gugur sebagian besar karena durasi musim di luar rentang yang wajar.

7.7.1 Mengapa durasi 92 hari menjadi bukti yang kuat


Angka 92 hari itu penting karena ia bukan besaran yang dimasukkan sebagai syarat, melainkan besaran yang **diukur** dari data dan ternyata kebetulan — atau lebih tepatnya, secara bebas — jatuh pada rentang yang benar. Penyaringan durasi musim memang menuntut nilai antara 60 dan 150 hari, tetapi rentang itu cukup lebar. Kenyataannya durasi yang terukur mengumpul di sekitar 92 hari, jauh di dalam rentang, bukan menumpuk di tepi. Bila kurva yang tertangkap adalah derau atau tanaman lain, durasi yang terukur akan tersebar merata di sepanjang rentang, atau menumpuk di salah satu ujungnya. Kenyataan bahwa nilai tengahnya berada di dekat umur padi sesungguhnya, dengan sebaran yang sempit (79 sampai 110 hari di antara persentil 25 dan 75), menunjukkan bahwa yang tertangkap adalah proses biologis yang nyata, bukan artefak.

Bukti kedua berasal dari kombinasi ketiga syarat yang harus terpenuhi sekaligus. Puncak EVI minimal 0,35 menyaring kurva yang terlalu lemah; durasi 60 sampai 150 hari menyaring pola umur yang tidak wajar; dan NDFI maksimal minimal 0,10 menuntut bukti genangan. Ketiga syarat itu menutup tiga jenis kekeliruan yang berbeda, dan peluang sebuah piksel non-padi memenuhi ketiganya secara kebetulan menjadi sangat

kecil. Karena itu, meskipun tidak ada verifikasi (verification) lapangan pada bab ini, kombinasi ketiga syarat memberikan keyakinan yang wajar bahwa himpunan piksel yang diterima memang didominasi sawah.

Perlu dicatat secara terbuka bahwa bukti ini bersifat tidak langsung. Yang ditunjukkan adalah bahwa kurva yang tertangkap **konsisten** dengan kurva padi, bukan bahwa setiap piksel yang diterima benar-benar padi. Penilaian yang lebih tegas terhadap mutu masker ini dilakukan pada Bab 8, di mana masker fenologi dibandingkan dengan peta tutupan lahan independen dan menghasilkan MCC 0,436 — nilai yang lebih baik daripada masker NDVI tunggal, tetapi masih tergolong sedang, bukan kuat.

7.8 Tanggal pembungaan dan jendela citra yang benar



Gambar 7.5. Hari pembungaan per piksel, memperlihatkan pola musim tanam yang bergeser antar tahun.

Titik puncak kurva EVI memberi tanggal pembungaan setiap piksel. Sebaran tanggal itu, pada piksel padi, adalah sebagai berikut.

Persentil	Tanggal
p5	30 Sep 2025
p25	6 Mar 2026
median	22 Mar 2026
p75	23 Apr 2026
p95	12 Jul 2026

Sebaran ini memperlihatkan pola musim tanam yang jelas. Puncak terbesar jatuh pada **Maret 2026**, dengan 11.609 piksel dari total 28.872. Artinya sebagian besar sawah di area kajian berbunga pada bulan Maret.

Ada juga kelompok yang lebih kecil berbunga pada September–Oktober 2025 dan pada Mei 2026. Keberadaan beberapa kelompok ini menunjukkan bahwa penanaman tidak serentak — ada beberapa gelombang tanam, yang wajar terjadi pada sistem irigasi bergilir.

Dari sebaran ini, jendela citra yang tepat dapat ditentukan: **24 Februari sampai 3 Mei 2026**, yaitu rentang antara persentil 25 dan persentil 75 tanggal pembungaan. Jendela ini mencakup sekitar separuh sawah yang berbunga paling serentak.

7.8.1 Tafsiran sebaran tanggal pembungaan dan kaitannya dengan irigasi bergilir

Sebaran tanggal pembungaan di atas perlu dibaca lebih cermat, karena di dalamnya terkandung informasi tentang cara sawah di Indramayu diatur pengairannya. Sebaran itu bukan satu puncak tunggal yang sempit, melainkan satu puncak besar yang diapit dua kelompok kecil.

Puncak besar pada Maret 2026 menampung 11.609 piksel, yaitu sekitar 40 persen dari seluruh piksel yang memiliki kurva valid. Puncak ini mewakili musim tanam utama, ketika sebagian besar petak ditanami dalam rentang waktu yang berdekatan. Pada bulan Maret, fase pembungaan berlangsung serentak di sebagian besar area kajian, dan inilah sebabnya jendela citra 24 Februari sampai 3 Mei 2026 dipilih: jendela itu mengapit puncak besar ini.

Kelompok kecil pada September–Oktober 2025 (dengan p5 jatuh pada 30 September 2025) mewakili petak-petak yang menanam lebih awal. Petak-petak ini kemungkinan berada pada blok irigasi yang mendapat air lebih dahulu, atau pada lahan yang mengandalkan air hujan awal, sehingga dapat mulai tanam lebih awal daripada kebanyakan petak. Kelompok ini kecil karena hanya sebagian petak yang mengikuti jadwal tanam awal.

Kelompok kecil pada Mei 2026 (dengan p95 jatuh pada 12 Juli 2026, artinya sebagian piksel berbunga pada Mei hingga Juli) mewakili petak-petak yang menanam lebih lambat. Petak-petak ini kemungkinan

berada pada blok irigasi yang mendapat air belakangan, atau menunggu panen musim sebelumnya selesai sebelum dapat mulai tanam.

Keseluruhan pola itu — satu puncak besar dengan dua kelompok kecil di kedua sisinya — adalah pola yang **khas sistem irigasi bergilir**. Pada sistem ini, air dialirkan ke blok-blok petak secara bergantian, sehingga waktu tanam bergeser mengikuti jadwal pengairan. Petak yang mendapat air lebih awal berbunga lebih awal; petak yang mendapat air belakangan berbunga lebih lambat. Sebagian besar petak berada pada golongan yang serentak — itulah puncak besar — sedangkan sebagian kecil petak menyimpang ke depan atau ke belakang.

Tafsiran ini memiliki konsekuensi praktis yang penting untuk pekerjaan pemetaan varietas. Karena jendela citra hanya mencakup satu puncak, **sebagian sawah pasti berada di luar jendela** pada fase yang salah. Jendela 24 Februari sampai 3 Mei 2026 dirancang untuk menangkap sekitar separuh sawah yang berbunga paling serentak, yaitu rentang antara persentil 25 dan persentil 75. Sawah yang berbunga pada kelompok September–Oktober 2025 atau Mei 2026 tidak tercakup pada fase puncaknya. Karena itu, setiap komposit (composite) citra yang dibangun dari jendela tunggal akan selalu memuat sebagian piksel padi pada fase vegetatif, bera, atau pematangan — dan ini adalah keterbatasan yang harus dilaporkan, bukan disembunyikan.

Persentil 5 dan persentil 95 menunjukkan betapa lebar sebaran itu: p5 jatuh pada 30 September 2025 dan p95 pada 12 Juli 2026, rentang hampir sepuluh bulan. Rentang seluas itu mencerminkan bahwa dalam satu area kajian, sawah dapat berbunga pada hampir sepanjang tahun. Inilah alasan mengapa pemilihan jendela tidak dapat menghilangkan masalah pencampuran fase secara total; yang dapat dilakukan hanyalah meminimalkannya dengan memusatkan jendela pada puncak terbesar.

7.9 Temuan yang mengubah arah analisis

Satu temuan dari bab ini perlu disampaikan di sini karena konsekuensinya besar, dan akan dibahas rinci pada Bab 11.

Komposit citra Sentinel-2 yang dipakai pada analisis awal ternyata diambil pada **1 Mei sampai 31 Agustus 2026**. Bandingkan dengan tanggal pembungaan median: **22 Maret 2026**.

Artinya komposit itu **mulai 39 hari setelah pembungaan median**. Ia tidak memuat fase puncak sama sekali.

Pengujian memperlihatkan hal itu dengan jelas. Ketika fase setiap piksel padi ditentukan untuk jendela komposit itu, hasilnya: 64,5 persen piksel berada pada fase vegetatif, 32,4 persen pada fase bera atau persiapan, 1,1 persen pada fase generatif, dan **0,0 persen pada fase puncak**. Hanya 29,9 persen piksel yang puncak EVI-nya jatuh di dalam jendela komposit.

Sebaran kelas fase di atas dihitung dengan cara yang membandingkan EVI rata-rata di dalam jendela terhadap kurva penuh. Cara itu tidak stabil terhadap pergeseran jendela — kelasnya berubah pada 56,8 sampai 71,4 persen piksel ketika jendela digeser 20 sampai 40 hari — dan kelas puncaknya praktis kosong. Angka itu tetap sah sebagai bukti bahwa jendela lama duduk pada fase yang salah. Tetapi bila sebaran kelas fase hendak dipakai menarik kesimpulan agronomis, angka itu harus dihitung ulang dari tanggal yang diturunkan dari puncak EVI (Bab 15.8).

Ini berarti komposit yang dianalisis memuat padi pada fase yang salah. Dan sebagaimana akan terlihat, inilah salah satu sebab mengapa hasil awal tampak tidak wajar.

Yang perlu dicatat secara terbuka: memperbaiki jendela tanggal **tidak** menyelesaikan seluruh masalah. Setelah jendela diperbaiki, masalah lain tetap muncul. Tetapi memperbaiki jendela tetap penting, karena pencampuran fase dalam satu komposit merusak asumsi model campuran linear — kerusakan yang lebih mendasar daripada masalah lain yang akan dibahas kemudian.

Satu hal yang perlu disorot mengenai angka 0,0 persen pada fase puncak. Angka itu bukan hasil pembulatan dari nilai kecil; ia berarti bahwa di dalam jendela komposit lama, praktis tidak ada piksel padi yang berada pada puncak EVI. Pada fase puncak, kurva EVI padi mencapai titik tertinggi selama hanya beberapa selang observasi (sekitar dua hingga empat pengamatan 16 harian). Karena komposit lama dimulai 39 hari setelah pembungaan median, seluruh jendela puncak telah terlewat sebelum komposit dimulai. Yang terekam justru fase sesudah puncak — vegetatif untuk petak yang menanam lebih lambat, dan bera atau persiapan untuk petak yang sudah selesai panen. Inilah gambaran paling jelas bahwa jendela lama secara sistematis salah, bukan sekadar kurang tepat.

Temuan ini sekaligus menegaskan pelajaran Bab 7 secara keseluruhan: pemilihan jendela citra adalah keputusan yang berdampak besar, dan keputusan itu harus didasarkan pada fenologi yang diukur, bukan pada tanggal yang dipilih karena ketersediaan data. Pada analisis awal, jendela dipilih tampaknya karena citra pada periode itu tersedia, tanpa memeriksa terlebih dahulu kapan sawah di area kajian sesungguhnya berbunga. Fenologi MODIS menyediakan cara untuk memeriksa hal itu sebelum analisis dijalankan — dan bab ini menunjukkan bahwa pemeriksaan itu memang diperlukan.

7.10 Yang perlu diingat dari bab ini

Pertama, variabilitas endmember adalah masalah inti pemisahan varietas, dan menekan variabilitas fase adalah cara paling langsung untuk mengatasinya.

Kedua, EVI lebih tepat daripada NDVI untuk padi karena NDVI jenuh pada biomassa tinggi, sedangkan justru fase puncak yang menjadi acuan [5].

Ketiga, kombinasi indeks vegetasi dan indeks genangan jauh lebih andal daripada indeks vegetasi saja. Hanya sawah yang memiliki pola genangan lalu tumbuh [4].

Keempat, durasi musim yang terukur — 92 hari — menjadi bukti tidak langsung yang kuat bahwa yang terdeteksi memang padi, karena rentangnya sesuai dengan umur varietas padi Indonesia.

Kelima, jendela citra harus ditentukan dari fenologi, bukan dari tanggal sembarang. Kesalahan pada langkah ini akan merusak seluruh analisis berikutnya.

Sebagai penutup, tiga catatan teknis dari bab ini layak diingat karena akan dipakai kembali pada bab-bab berikutnya. Pertama, tapis Savitzky–Golay dengan jendela tujuh titik dan orde dua dipilih agar puncak kurva tetap pada tempatnya; parameter ini bukan pilihan sembarang dan mengubahnya akan menggeser tanggal pembungaan. Kedua, kanal DetailedQA MOD13Q1 dibaca dengan operasi bitwise AND dengan tiga untuk memperoleh dua bit mutu indeks vegetasi; penyaringan ini menyisakan sekitar 52 persen observasi, angka yang wajar untuk daerah tropis. Ketiga, setiap deret waktu yang memuat lebih dari satu musim harus

dipecah dengan membatasi jendela pencarian 150 hari, karena tanpa pembatasan itu durasi musim yang terhitung dapat melampaui 700 hari dan seluruh piksel akan gugur pada penyaringan.

Dengan fenologi yang terukur ini, pekerjaan pada bab-bab berikutnya memiliki pijakan yang jelas: kapan sawah berbunga, seberapa lama satu musim berlangsung, dan jendela tanggal mana yang paling tepat untuk mengambil citra. Bab 8 akan memakai hasil ini untuk memperkuat masker padi, sedangkan Bab 11 akan menelusuri konsekuensi dari jendela citra yang ternyata salah pada analisis awal.

BAB VIII MASKER PADI DAN CARA MENILAINYA DENGAN BENAR

8.1 Mengapa masker diperlukan

Penguraian spektral (spectral unmixing) pada dasarnya adalah alat untuk menguraikan campuran. Tetapi tidak semua campuran menarik untuk diuraikan. Bila kita ingin tahu varietas (variety) padi, maka menguraikan piksel yang berisi air atau tanah atau bangunan tidak memberi informasi berguna — dan yang lebih buruk, hasilnya dapat mengacaukan statistik keseluruhan.

Karena itu sebelum penguraian dijalankan, piksel yang bukan padi disingkirkan lebih dahulu. Proses ini disebut **masking**, dan hasilnya adalah **masker (mask) padi**: sebuah peta biner yang menyatakan piksel mana yang dianggap padi dan mana yang tidak.

Bab ini membahas cara menyusun masker itu, dan — bagian yang paling mudah salah — cara menilai apakah masker itu berkualitas baik.

8.2 Menyusun masker: tiga syarat

Masker padi pada pekerjaan ini dibangun dari tiga syarat yang harus terpenuhi sekaligus.

Syarat pertama: mutu data. Kanal (band) *Scene Classification Layer* pada Sentinel-2 memberi kelas untuk setiap piksel: vegetasi, tanah, air, awan, bayangan awan, salju, dan seterusnya. Hanya kelas-kelas yang sah yang diterima — vegetasi, bukan vegetasi, air, dan tak terklasifikasi. Piksel yang tertutup awan atau bayangannya langsung disingkirkan.

Syarat kedua: bukan air. Sawah memang digenangi air pada sebagian musimnya, tetapi badan air permanen seperti sungai, kolam, dan laut harus disingkirkan. Penyaringnya adalah **NDWI** (*Normalized Difference Water Index*), dihitung dari kanal hijau dan inframerah dekat. Piksel dengan NDWI positif adalah air, dan disingkirkan.

Syarat ketiga: bervegetasi. Piksel harus menunjukkan kehijauan yang cukup. Penyaringnya adalah **NDVI** dengan ambang (threshold) 0,35.

Ketiga syarat ini digabungkan, dan hasilnya adalah masker padi awal. Pada data Indramayu, masker ini menerima 1.994.687 piksel dari 4.276.094 piksel sah — atau 46,6 persen.

8.2.1 Cara kerja Scene Classification Layer kelas per kelas

Kanal *Scene Classification Layer* (SCL) pada Sentinel-2 bukan kanal spektral, melainkan kanal tematik hasil klasifikasi otomatis yang disertakan pada setiap produk tingkat L2A. Setiap piksel diberi satu bilangan bulat antara 0 dan 11 yang menyatakan kelas penutup permukaannya. Karena sifatnya tematik, kanal ini tidak boleh diperlakukan seperti kanal reflektansi (*reflectance*) — dan kekeliruan memperlakukannya demikian sudah dibahas pada Bab 6, ketika pembagian seluruh kanal dengan 10.000 membuat nilai kelas rusak menjadi 0,0004 dan seterusnya, sehingga penyaringan awan gagal total dan tidak ada satu piksel pun yang lolos.

Kedua belas kelas itu beserta artinya adalah sebagai berikut. Kelas 0 berarti tanpa data (*no data*), yaitu piksel yang tidak memiliki nilai sama sekali. Kelas 1 berarti piksel jenuh atau cacat (*saturated or defective*). Kelas 2 adalah bayangan gelap topografi (*cast shadows*), yaitu bayangan yang disebabkan oleh relief medan. Kelas 3 adalah bayangan awan (*cloud shadows*). Kelas 4 adalah vegetasi (*vegetation*). Kelas 5 adalah bukan vegetasi (*not vegetated*), yang mencakup tanah terbuka, lahan kosong, bangunan, dan permukaan tak bervegetasi lainnya. Kelas 6 adalah air (*water*). Kelas 7 adalah tak terklasifikasi (*unclassified*). Kelas 8 adalah awan dengan probabilitas sedang (*cloud medium probability*). Kelas 9 adalah awan dengan probabilitas tinggi (*cloud high probability*). Kelas 10 adalah siros tipis (*thin cirrus*). Kelas 11 adalah salju atau es (*snow or ice*).

Bagi pekerjaan ini, pertanyaannya bukan "kelas apa ini", melainkan "kelas mana yang sah untuk sawah". Sawah, sepanjang musimnya, dapat muncul pada beberapa kelas sekaligus, dan justru itulah yang membuat penyaringan SCL perlu dipahami, bukan sekadar dijalankan. Pada fase bertunas dan bervegetasi rapat, sawah masuk kelas 4 (vegetasi). Pada fase persiapan lahan, ketika tanah dibajak dan belum ditanami, sawah justru masuk kelas 5 (bukan vegetasi) — sama seperti tanah kering biasa. Pada fase penggenangan, permukaan sawah yang tertutup air dapat masuk kelas 6 (air), terutama bila genangannya cukup dalam dan luas. Sementara itu, piksel yang tidak berhasil diklasifikasikan masuk kelas 7 (tak terklasifikasi).

Karena itu, empat kelas yang diterima untuk keperluan masker padi adalah kelas 4, 5, 6, dan 7. Kelas 4 dan 6 sudah jelas: vegetasi adalah penampakan sawah yang tumbuh, dan air adalah penampakan sawah yang

tergenang. Kelas 5 perlu diterima meskipun tampak berlawanan dengan gagasan "padi", karena fase persiapan lahan adalah bagian sah dari siklus sawah — sebuah piksel yang hari ini tampak sebagai tanah terbuka bisa jadi adalah sawah yang baru dibajak, dan menolaknya akan membuang bagian awal musim (season). Kelas 7 juga diterima karena menolaknya berarti membuang piksel yang mungkin sah hanya karena klasifikasi otomatisnya gagal menetapkan kelas.

Sebaliknya, delapan kelas sisanya ditolak tanpa kecuali. Kelas 0 dan 1 ditolak karena pikselnya tidak membawa nilai yang dapat dipercaya. Kelas 2 dan 3 ditolak karena bayangan — baik bayangan topografi maupun bayangan awan — bukan penutup permukaan, melainkan gangguan pencahayaan yang membuat reflektansi tampak lebih gelap daripada seharusnya. Kelas 8, 9, dan 10 ditolak karena ketiganya menyatakan keberadaan awan pada berbagai tingkat keyakinan, dan awan menutupi permukaan di bawahnya sehingga nilai spektral yang terukur adalah nilai awan, bukan nilai sawah. Kelas 11 ditolak karena salju atau es tidak mungkin berada di sawah dataran rendah tropis, dan bila kelas ini muncul, itu pertanda kesalahan klasifikasi yang justru perlu dicurigai.

Perlu ditegaskan satu hal yang mudah terlewat: SCL adalah hasil klasifikasi otomatis, bukan kebenaran lapangan. Ia sendiri dapat salah, terutama pada sawah yang tergenang sebagian, di mana batas antara kelas 4, 5, dan 6 bisa kabur. Karena itu SCL dipakai sebagai penyaring kasar, bukan sebagai penentu akhir. Penentu akhir tetap analisis spektral dan fenologi (phenology) yang dibahas pada bagian berikutnya.

8.2.2 Penurunan indeks spektral dan alasan pemilihannya

Ketiga penyaring pada 8.2 tidak dipilih secara sembarang; masing-masing dirancang untuk satu keperluan, dan bentuk matematisnya mengikuti keperluan itu. Memahami penurunannya penting, karena di situlah terletak alasan mengapa indeks tertentu cocok dan indeks lain tidak.

NDVI. *Normalized Difference Vegetation Index* dihitung sebagai

$$\text{NDVI} = (\rho_{\text{NIR}} - \rho_{\text{Merah}}) / (\rho_{\text{NIR}} + \rho_{\text{Merah}})$$

dan pada Sentinel-2 memakai kanal B8 (842 nm) sebagai inframerah dekat dan B4 (665 nm) sebagai merah. Bentuknya bukan kebetulan. Klorofil menyerap cahaya merah dengan kuat, sedangkan jaringan mesofil daun memantulkan inframerah dekat dengan kuat. Kedua kanal itu karena

itu bergerak berlawanan arah ketika tanaman bertambah hijau: merah makin terserap, inframerah dekat makin terpantul. Selisih keduanya membesarkan sinyal itu, sedangkan pembagian dengan jumlahnya membuat hasilnya **tak-bergantung pada terang-gelapnya pencahayaan**: bila seluruh nilai dikalikan suatu faktor, pembilang dan penyebut sama-sama dikalikan, sehingga hasil baginya tetap. Sifat normalisasi inilah yang membuat NDVI dapat dibandingkan antar tanggal dan antar lokasi. Nilainya terbatas antara -1 dan +1; vegetasi rapat memberi nilai tinggi, air dan tanah memberi nilai rendah atau negatif. Pada data ini, NDVI piksel padi memiliki nilai tengah 0,548 dengan persentil (percentile) 5 sebesar 0,366 dan persentil 95 sebesar 0,766. Ambang 0,35 yang dipakai karena itu diletakkan tepat di bawah persentil 5, sehingga menerima kira-kira 95 persen piksel padi yang paling hijau sekaligus menyingkirkan permukaan tak bervegetasi.

NDWI. *Normalized Difference Water Index* memakai bentuk normalisasi yang sama, tetapi dengan pasangan kanal yang berbeda:

$$\text{NDWI} = (\rho_{\text{Hijau}} - \rho_{\text{NIR}}) / (\rho_{\text{Hijau}} + \rho_{\text{NIR}})$$

Pada Sentinel-2 kanal hijau adalah B3 (560 nm), dan inframerah dekat tetap B8. Alasan pemilihan pasangan ini adalah sifat air: air menyerap inframerah dekat dengan sangat kuat, tetapi memantulkan cahaya hijau relatif lebih baik. Akibatnya, di atas permukaan air, kanal hijau lebih terang daripada kanal inframerah dekat, dan selisih ($\rho_{\text{Hijau}} - \rho_{\text{NIR}}$) menjadi **positif**. Di atas vegetasi dan tanah, keadaannya terbalik: inframerah dekat lebih terang, sehingga NDWI bernilai negatif. Karena itu NDWI positif dipakai sebagai penanda air. Indeks ini berperan sebagai penyaring kedua — penyingkir badan air permanen — dan perlu ditegaskan bahwa yang disingkirkan adalah air **permanen** (sungai, kolam, laut), bukan genangan (inundation) musiman di sawah. Genangan musiman justru menjadi ciri yang dicari, dan penanganannya memakai indeks ketiga.

NDFI. *Normalized Difference Flooding Index* dirancang khusus untuk mendeteksi genangan, dan dipakai dalam algoritme PhenoRice [4]:

$$\text{NDFI} = (\rho_{\text{NIR}} - \rho_{\text{SWIR}}) / (\rho_{\text{NIR}} + \rho_{\text{SWIR}})$$

di mana SWIR adalah inframerah gelombang pendek (shortwave infrared). Bentuknya tetap normalisasi yang sama, tetapi pasangan kanalnya digeser ke inframerah gelombang pendek. Alasannya kembali ke

sifat air: air menyerap inframerah gelombang pendek dengan sangat kuat, bahkan lebih kuat daripada penyerapannya terhadap inframerah dekat. Pada permukaan yang tergenang, karena itu, inframerah gelombang pendek turun tajam sementara inframerah dekat tidak seturun itu, sehingga selisih ($\rho_{\text{NIR}} - \rho_{\text{SWIR}}$) membesar dan NDFI menjadi tinggi. Tanah kering menunjukkan keadaan sebaliknya. Inilah sebabnya NDFI dapat menangkap genangan pada permukaan yang masih memuat tanah dan sisa tanaman — persis keadaan sawah pada awal musim tanam (cropping season).


Ketiga indeks itu bersama-sama membentuk logika masker: NDVI menyaring kehijauan, NDWI membuang badan air, dan NDFI membuktikan adanya genangan musiman. Yang penting dicatat adalah bahwa ketiganya memakai bentuk matematis yang identik — selisih dibagi jumlah — dan yang membedakan hanyalah pasangan kanalnya. Pemilihan pasangan kanal itulah yang menyandikan pengetahuan tentang sifat fisik objek yang ingin dikenali. Dengan kata lain, indeks bukan rumus ajaib, melainkan cara menerjemahkan perilaku spektral suatu bahan menjadi satu bilangan yang dapat diibandingkan.

8.3 Kelemahan masker yang perlu diakui

Angka 46,6 persen itu langsung menimbulkan kecurigaan. Sawah seluas 46,6 persen dari seluruh area kajian adalah angka yang terlalu besar untuk dataran pantai utara Jawa Barat, meskipun daerah itu memang merupakan lumbung padi.


Kecurigaan itu terbukti benar. Masker yang dibangun dari tiga syarat di atas sebenarnya bukan masker padi, melainkan masker "**bervegetasi dan bukan air**". Syaratnya terlalu longgar. Pohon, perkebunan, dan tanaman lain yang bervegetasi rapat juga memenuhi ketiga syarat itu, dan ikut masuk sebagai "padi".

Untuk mengatasi ini, masker diperkuat dengan **analisis fenologi multi-temporal** yang dibahas pada Bab 7. Sebuah piksel hanya diterima sebagai padi bila ia juga menunjukkan pola pertumbuhan yang khas padi: memiliki puncak EVI yang cukup tinggi, durasi musim yang wajar, dan bukti genangan di awal musim.



Gambar 8.1. Masker padi dari analisis fenologi MODIS pada resolusi 250 meter.

Penguatan ini membuang **44,9 persen** piksel dari masker awal, menyisakan 1.099.658 piksel. Dengan kata lain, hampir separuh dari apa yang semula disebut "padi" sebenarnya bukan padi.



Gambar 8.2. Masker fenologi MODIS setelah diproyeksikan ke grid Sentinel-2 berukuran 30 meter.

8.4 Pengaruh masker yang lebih ketat

Pertanyaan yang wajar muncul: apakah masker yang lebih ketat mengubah hasil penguraian?

Jawabannya: **tidak secara berarti**, dan jawaban ini penting untuk dipahami.

Penguraian dijalankan dua kali pada piksel padi yang sama — sekali dengan masker NDVI saja, sekali dengan masker gabungan. Hasilnya sebagai berikut.

Varietas	Masker NDVI	Masker gabungan	Selisih
Ciherang	0,0849	0,0840	-1,0%
IR64	0,0777	0,0773	-0,6%
Inpari32	0,1620	0,1642	+1,3%
Inpari32_WBC	0,2461	0,2505	+1,8%
Mekongga	0,4293	0,4240	-1,2%

Seluruh selisih berada di bawah dua persen, dan urutan dominasi tidak berubah.

Untuk memastikan sebabnya, fraksi (fraction) dihitung ulang pada **himpunan piksel yang sama** untuk kedua masker. Hasilnya **identik sampai empat angka desimal**. Artinya masker tidak mengubah hasil penguraian per piksel; ia hanya **memilih subset piksel** yang dianalisis.

Kesimpulan ini penting untuk arah pengembangan perangkat lunak: **perbaiki masker tidak akan memperbaiki fraksi varietas**. Yang diperbaiki oleh masker yang lebih baik adalah hal-hal lain — cakupan yang lebih wajar, hilangnya piksel ekstrem (extreme pixel), dan kepercayaan yang lebih tinggi pada hasil. Tetapi angkanya tidak akan berubah.

Yang benar-benar mengubah fraksi hanyalah dua hal: endmember (endmember) yang lebih baik, atau kemampuan memisahkan kelas yang sebelumnya tidak dapat dipisahkan. Bab 10 dan 11 membahas keduanya.

8.5 Jebakan pertama: F1 menyesatkan pada kelas tidak seimbang

Sekarang masuk ke bagian yang paling mudah salah, dan yang hampir menyesatkan penulis sendiri.

Untuk menilai mutu masker, masker dibandingkan dengan peta tutupan lahan independen — dalam hal ini ESA WorldCover, yang menyediakan kelas lahan pertanian. Ukuran yang biasa dipakai untuk

perbandingan semacam ini adalah **F1**, yaitu rata-rata harmonik dari presisi dan recall.

Masalahnya, pada area kajian ini lahan pertanian mencakup **54,9 persen** wilayah. Kelasnya sangat tidak seimbang.

Untuk menunjukkan mengapa ini menjadi masalah, dilakukan pengujian dengan masker "liar": sebuah masker yang menjawab "**semua piksel adalah padi**", tanpa melakukan analisis apa pun. Masker itu jelas tidak berguna. Tetapi F1-nya adalah **70,9 persen** — hampir sama dengan masker fenologi yang sungguhan (71,8 persen).

Inilah buktinya bahwa F1 menyesatkan di sini. Penyebabnya mudah dipahami: karena lahan pertanian memang mencakup lebih dari separuh wilayah, sebuah masker yang menjawab "semua padi" akan benar pada separuh kasus hanya karena kebetulan. Recall-nya sempurna, presisinya sama dengan proporsi area, dan F1-nya menjadi tinggi.

8.6 Metrik yang benar

Untuk kelas yang tidak seimbang, ukuran yang tepat adalah **MCC** (*Matthews Correlation Coefficient*) dan **kappa**, yang keduanya memperhitungkan keempat sel matriks kekeliruan (confusion matrix) sekaligus — benar positif, salah positif, salah negatif, dan benar negatif — bukan hanya dua di antaranya.

Nilai MCC berkisar dari -1 sampai $+1$. Nilai 0 berarti tidak ada informasi sama sekali, setara menebak secara acak. Sebagai acuan tafsiran: di bawah $0,2$ tidak berguna; $0,2$ sampai $0,4$ lemah; $0,4$ sampai $0,6$ sedang; $0,6$ sampai $0,8$ kuat; dan di atas $0,8$ sangat kuat.

Ukuran ketiga yang dipakai adalah **IoU** (*Intersection over Union*), atau disebut juga indeks Jaccard: luas irisan dibagi luas gabungan. Ukuran ini lebih ketat daripada F1 dan lebih sulit dimanipulasi oleh ketidakseimbangan kelas.

Hasil lengkap pengukuran disajikan pada tabel berikut.

Masker	Presisi	Recall	F1	MCC	Kappa	IoU
SEMUA dianggap padi (liar)	54,9%	100,0%	70,9%	0,000	0,000	54,9%

Masker	Presisi	Recall	F1	MCC	Kappa	IoU
SEMUA bukan padi	0,0%	0,0%	0,0%	0,000	0,000	0,0%
Acak 55%	54,9%	54,9%	54,9%	0,001	0,001	37,9%
A. Sentinel-2 NDVI saja	64,3%	53,8%	58,6%	0,175	0,172	41,4%
B. MODIS fenologi saja	78,1%	66,4%	71,8%	0,436	0,430	56,0%
C. A DAN B (irisan)	69,5%	32,0%	43,9%	0,171	0,141	28,1%
D. A ATAU B (gabungan)	71,9%	88,2%	79,2%	0,491	0,475	65,6%

Perhatikan baris pertama. Masker liar (naive mask) memperoleh F1 70,9 persen, tetapi MCC dan kappa-nya tepat **nol**. Kedua ukuran itu mengungkap kebenaran yang disembunyikan F1: masker itu tidak membawa informasi apa pun.

8.7 Tafsiran hasil

Tiga kesimpulan dapat ditarik dari tabel di atas.

Pertama, masker fenologi MODIS mengalahkan masker NDVI Sentinel-2 secara jelas: MCC 0,436 dibandingkan 0,175. Dengan tafsiran yang dipakai di atas, masker NDVI tunggal berada di bawah ambang "berguna", sedangkan masker fenologi berada pada kelas "sedang".

Kedua, gabungan keduanya memberi hasil terbaik: MCC 0,491 dengan recall 88,2 persen. Sebaliknya, **irisan** keduanya justru lebih buruk daripada masker acak (MCC 0,171) dan tidak boleh dipakai.

Mengapa gabungan lebih baik daripada masing-masing? Karena kesepakatan antara kedua masker hanya rendah — kappa antara keduanya 0,155. Artinya keduanya menangkap hal yang berbeda: NDVI menangkap

kehijauan, sedangkan fenologi menangkap pola tumbuh. Karena yang ditangkap berbeda, menggabungkannya menambah informasi. Sebaliknya, mengambil irisannya justru membuang informasi, karena menuntut kedua metode setuju — dan keduanya memang sering tidak setuju.

Ketiga, dan ini yang perlu ditekankan: meskipun masker fenologi mengalahkan masker NDVI, **keduanya masih berada pada kelas sedang, bukan kuat**. MCC 0,436 dan 0,491 tidak cukup untuk disebut tervalidasi dengan baik. Yang benar dikatakan adalah: masker fenologi lebih baik daripada NDVI tunggal, dan gabungan keduanya lebih baik lagi, tetapi semuanya belum mencapai mutu yang dapat diandalkan tanpa verifikasi (verification) lapangan.

8.8 Satu pembanding yang perlu selalu disertakan

Dari pengalaman pada bab ini, satu kebiasaan penilaian perlu dibakukan: **selalu sertakan masker liar dan masker acak sebagai pembanding**.

Masker liar — yang menjawab "semua padi" — dan masker acak bukan sekadar formalitas. Keduanya berfungsi sebagai **garis dasar**: bila masker yang sungguhan tidak jauh lebih baik daripada keduanya, maka masker itu tidak layak dipakai, sebagus apa pun angkanya terlihat.

Pada data ini, pembanding acak memberi F1 52,2 persen. Dengan garis dasar itu, masker NDVI tunggal (F1 58,6 persen) hanya sedikit di atasnya — yang menjelaskan mengapa MCC-nya rendah. Masker gabungan (F1 79,2 persen) jauh di atasnya — yang menjelaskan mengapa MCC-nya paling tinggi.

Kebiasaan ini sederhana, tetapi menyelamatkan dari kesalahan yang mahal: melaporkan masker yang tampak bagus padahal tidak membawa informasi.

8.9 Yang perlu diingat dari bab ini

Pertama, masker yang dibangun dari NDVI dan NDWI saja sebenarnya adalah masker "bervegetasi dan bukan air", bukan masker padi. Pohon dan perkebunan ikut terbawa.

Kedua, memperkuat masker dengan fenologi membuang 44,9 persen piksel, dan itu memang perlu. Tetapi memperbaiki masker **tidak** mengubah fraksi varietas — ia hanya memilih subset piksel.

Ketiga, F1 menyesatkan pada kelas yang tidak seimbang. Masker liar memperoleh F1 70,9 persen. Gunakan MCC dan kappa.

Keempat, masker fenologi MODIS mengalahkan NDVI tunggal (MCC 0,436 dibandingkan 0,175), dan gabungan keduanya paling baik (MCC 0,491, recall 88,2 persen). Irisan keduanya justru lebih buruk daripada acak.

Kelima, selalu sertakan pembanding acak dan pembanding liar (naive baseline). Tanpa keduanya, tidak ada cara mengetahui apakah sebuah masker benar-benar membawa informasi.

8.10 Membaca matriks kekeliruan dengan benar

Seluruh metrik pada bagian sebelumnya berasal dari satu tabel kecil yang sering dilewati begitu saja: **matriks kekeliruan** (*confusion matrix*). Karena semua penilaian bergantung padanya, tabel itu perlu dipahami isi per selnya sebelum angkanya dipercaya.

Untuk penilaian masker padi, matriksnya berukuran dua kali dua. Sumbu satu menyatakan keadaan sebenarnya menurut acuan — dalam hal ini apakah piksel termasuk lahan pertanian menurut ESA WorldCover. Sumbu lain menyatakan jawaban masker yang dinilai. Dari perpotongan keduanya diperoleh empat sel:

- **Benar positif (TP)**: piksel yang oleh acuan adalah lahan pertanian, dan oleh masker juga disebut padi.
- **Salah positif (FP)**: piksel yang oleh acuan bukan lahan pertanian, tetapi oleh masker disebut padi. Ini adalah "salah tuduh" — masker memasukkan sesuatu yang seharusnya di luar.
- **Salah negatif (FN)**: piksel yang oleh acuan adalah lahan pertanian, tetapi oleh masker dinyatakan bukan padi. Ini adalah "kelewatan" — masker membuang sesuatu yang seharusnya masuk.
- **Benar negatif (TN)**: piksel yang oleh acuan bukan lahan pertanian, dan oleh masker juga dinyatakan bukan padi.

Dua sel pertama, TP dan FP, hanya melihat baris "yang dinyatakan padi" oleh masker. Dua sel terakhir melengkapi gambaran. Kesalahan terbesar dalam menilai masker adalah membaca hanya sebagian sel. Presisi hanya memakai TP dan FP; recall hanya memakai TP dan FN. Keduanya, dan karena itu F1 juga, **tidak pernah menyentuh TN** — padahal di situlah letak sebagian besar wilayah pada persoalan yang tidak seimbang.

Mari lihat baris masker liar pada tabel 7.6. Karena masker itu menyatakan **semua** piksel sebagai padi, tidak ada satu pun piksel yang dinyatakan bukan padi. Akibatnya TN bernilai nol, dan FP adalah seluruh wilayah yang bukan lahan pertanian. Karena acuan menetapkan lahan pertanian 54,9 persen, maka $TP = 54,9$ persen dari total dan $FP = 45,1$ persen. Presisinya tepat 54,9 persen — sama dengan proporsi area — recall-nya 100 persen karena tidak ada satu pun kasus positif yang terlewat, dan F1-nya menjadi 70,9 persen. Semua angka itu terlihat "wajar" padahal masker itu tidak melakukan pekerjaan apa pun. Yang membongkar kepalsuan itu adalah sel TN: karena TN nol, seluruh perkalian silang pada MCC menjadi nol, dan MCC-nya tepat 0,000. Sel yang "tidak terpakai" oleh F1 itulah yang menyelamatkan penilaian.

Karena itu, kebiasaan pertama dalam membaca tabel penilaian masker bukan membaca F1, melainkan **memeriksa keempat sel**. Bila TN nol atau FP sangat besar, waspadalah: angka presisi dan recall mungkin terlihat baik hanya karena susunan area, bukan karena masker bekerja.

8.11 Matematika MCC, kappa Cohen, dan IoU dengan contoh

Setelah keempat sel diketahui, ketiga metrik dapat dihitung. Bagian ini menurunkan rumusnya dan mengerjakan satu contoh kecil yang dapat diikuti langkah demi langkah. Contoh ini **ilustratif** — ia dipakai semata untuk memperlihatkan cara kerja perhitungan, bukan untuk menyatakan hasil pengukuran pada data Indramayu. Hasil sebenarnya ada pada tabel 7.6.

Andaikan dari 100 piksel yang diperiksa, matriks kekeliruannya adalah: $TP = 30$, $FP = 15$, $FN = 10$, dan $TN = 45$. Jumlah seluruhnya memang 100, dan jumlah piksel yang oleh acuan dianggap padi adalah $TP + FN = 40$, sedangkan yang oleh masker dinyatakan padi adalah $TP + FP = 45$.

Presisi menjawab pertanyaan "dari semua yang disebut padi oleh masker, berapa yang benar?":

$$\text{Presisi} = TP / (TP + FP) = 30 / 45 = 0,6667 \rightarrow 66,7 \text{ persen}$$

Recall menjawab pertanyaan "dari semua yang sebenarnya padi, berapa yang berhasil ditemukan oleh masker?":

$$\text{Recall} = TP / (TP + FN) = 30 / 40 = 0,7500 \rightarrow 75,0 \text{ persen}$$

F1 adalah rata-rata harmonik keduanya, yang menghukum nilai yang paling lemah:

$$F1 = 2 \cdot (\text{Presisi} \cdot \text{Recall}) / (\text{Presisi} + \text{Recall}) = 2 \cdot (0,6667 \cdot 0,7500) / (0,6667 + 0,7500) = 1,0000 / 1,4167 = 0,7059 \rightarrow 70,6 \text{ persen}$$

IoU, atau indeks Jaccard, membandingkan luas irisan dengan luas gabungan. Luas irisan adalah TP; luas gabungan adalah semua yang disebut padi oleh salah satu pihak, yaitu TP + FP + FN:

$$\text{IoU} = \text{TP} / (\text{TP} + \text{FP} + \text{FN}) = 30 / (30 + 15 + 10) = 30 / 55 = 0,5455 \rightarrow 54,5 \text{ persen}$$

Terlihat bahwa IoU selalu lebih rendah daripada F1 untuk matriks yang sama. Hubungan keduanya bersifat tetap: $F1 = 2 \cdot \text{IoU} / (1 + \text{IoU})$. Karena itu IoU lebih ketat, dan masker yang tampak baik pada F1 belum tentu baik pada IoU.

MCC adalah yang paling berbeda, karena ia memakai keempat sel sekaligus:

$$\text{MCC} = (\text{TP} \cdot \text{TN} - \text{FP} \cdot \text{FN}) / \text{akar}((\text{TP} + \text{FP})(\text{TP} + \text{FN})(\text{TN} + \text{FP})(\text{TN} + \text{FN}))$$

Untuk contoh ini:

$$\begin{aligned} \text{pembilang} &= (30 \cdot 45) - (15 \cdot 10) = 1350 - 150 = 1200 \text{ penyebut} = \\ \text{akar}(45 \cdot 40 \cdot 60 \cdot 55) &= \text{akar}(5.940.000) \approx 2437,2 \text{ MCC} = 1200 / 2437,2 \\ &= 0,4924 \rightarrow 0,492 \end{aligned}$$

Perhatikan bentuk pembilangnya: TP·TN dikurangi FP·FN. Inilah inti MCC. Ia besar hanya bila masker benar **pada kedua sisi sekaligus** — banyak benar positif **dan** banyak benar negatif. Bila salah satu sel benar negatif kosong, seperti pada masker liar, pembilangnya menjadi nol berapa pun besar TP-nya. Inilah sebabnya MCC tidak dapat ditipu oleh ketidakseimbangan kelas.

Kappa Cohen mengukur seberapa jauh kesepakatan melebihi kesepakatan yang dapat terjadi secara kebetulan. Ia dihitung dalam dua langkah. Pertama, kesepakatan teramati (*observed agreement*):

$$p_o = (\text{TP} + \text{TN}) / N = (30 + 45) / 100 = 0,7500$$

Kedua, kesepakatan yang diharapkan terjadi secara kebetulan (*expected agreement*), dihitung dari hasil pinggir tabel:

$$p_e = [(TP + FP)(TP + FN) + (FN + TN)(FP + TN)] / N^2 = [(45)(40) + (55)(60)] / 10.000 = (1800 + 3300) / 10.000 = 0,5100$$

Kappa adalah selisih keduanya, dinormalkan terhadap ruang yang tersisa di atas kebetulan:

$$Kappa = (p_o - p_e) / (1 - p_e) = (0,7500 - 0,5100) / (1 - 0,5100) = 0,2400 / 0,4900 = 0,4898 \rightarrow 0,490$$

Pada contoh ini MCC (0,492) dan kappa (0,490) hampir sama. Kesamaan itu bukan kebetulan: untuk tabel dua kali dua keduanya sebenarnya saling terhubung secara matematis, sehingga sering memberi nilai yang berdekatan. Karena itu pada laporan buku ini keduanya disajikan berdampingan — bila keduanya berbeda jauh, itu pertanda ada yang perlu diperiksa.

Yang perlu dicatat dari ketiga perhitungan itu adalah **pembagian tugas** di antara metrik. Presisi, recall, dan F1 hanya membaca dua sel; IoU membaca tiga sel; MCC dan kappa membaca keempatnya. Semakin banyak sel yang dibaca, semakin sulit metrik itu ditipu oleh susunan area. Itulah alasan mengapa pada kelas yang tidak seimbang, MCC dan kappa harus dilaporkan, dan F1 tidak boleh berdiri sendiri.

8.12 Mengapa F1 gagal pada kelas tidak seimbang: contoh angka

Rumus saja tidak cukup meyakinkan; kekeliruan F1 paling jelas terlihat ketika dua masker dibandingkan dan keduanya diberi peringkat yang berlawanan oleh F1 dan MCC. Contoh berikut, seperti contoh pada bagian sebelumnya, bersifat **ilustratif** untuk memperlihatkan mekanismenya.

Ambil satu wilayah dengan prevalensi (prevalence) lahan pertanian 55 persen, sama dengan keadaan pada area kajian ini (54,9 persen). Bandingkan dua masker hipotetis pada 1.000 piksel.

Masker pertama adalah masker liar yang menyatakan semuanya padi: TP = 550, FP = 450, FN = 0, TN = 0. Hitung metriknya:

$$\begin{aligned} \text{Presisi} &= 550 / 1000 = 0,550 \rightarrow 55,0 \text{ persen} \\ \text{Recall} &= 550 / 550 = 1,000 \rightarrow 100,0 \text{ persen} \\ \text{F1} &= 2 \cdot (0,550 \cdot 1,000) / (0,550 + 1,000) = 1,100 / \end{aligned}$$

$$1,550 = 0,7097 \rightarrow 70,9 \text{ persen MCC} = (550 \cdot 0 - 450 \cdot 0) / \text{akar}(1000 \cdot 550 \cdot 450 \cdot 550) = 0 / \dots = 0,000$$

Masker kedua adalah masker yang benar-benar bekerja, tetapi lebih berhati-hati: TP = 300, FP = 50, FN = 250, TN = 400. Metriknya:

$$\begin{aligned} \text{Presisi} &= 300 / 350 = 0,857 \rightarrow 85,7 \text{ persen Recall} = 300 / 550 = 0,545 \rightarrow 54,5 \text{ persen} \\ F1 &= 2 \cdot (0,857 \cdot 0,545) / (0,857 + 0,545) = 0,934 / 1,402 = 0,6667 \rightarrow 66,7 \text{ persen} \\ MCC &= (300 \cdot 400 - 50 \cdot 250) / \text{akar}(350 \cdot 550 \cdot 450 \cdot 400) = (120.000 - 12.500) / \text{akar}(34.650.000.000) = 107.500 / 186.145 \approx 0,453 \end{aligned}$$

Sekarang bandingkan peringkatnya. Menurut **F1**, masker liar (70,9 persen) lebih baik daripada masker yang benar-benar bekerja (66,7 persen). Menurut **MCC**, masker liar (0,000) sama sekali tidak berguna sedangkan masker kedua (0,453) membawa informasi nyata. F1 dan MCC memberi jawaban yang **berlawanan**.

Mengapa F1 salah? Karena F1 hanya melihat baris "yang disebut padi". Pada masker liar, seluruh piksel disebut padi, sehingga tidak ada kasus positif yang terlewat — recall-nya sempurna. F1 tidak pernah "menghukum" masker itu karena menyebut seluruh non-pertanian sebagai padi, sebab hukuman itu hanya muncul lewat presisi, dan presisinya (55 persen) justru tampak wajar karena prevalensinya memang 55 persen. Pada kelas yang seimbang — misalnya 50 banding 50 — sebuah masker yang menyebut semuanya positif akan memperoleh presisi 50 persen tetapi MCC tetap nol; masalahnya, semakin tidak seimbang kelasnya, semakin tinggi plafon F1 yang dapat dicapai tanpa informasi apa pun. Pada prevalensi 90 persen, masker liar bahkan akan memperoleh F1 sekitar 95 persen. Inilah sifat yang membuat F1 berbahaya: **plafon palsu naik seiring ketidakseimbangan kelas**, tepat pada keadaan di mana penilaian paling dibutuhkan.

Ada satu hal lagi yang perlu disadari. Pada contoh di atas, masker yang lebih baik justru punya recall lebih rendah. Itu wajar dan bukan cacat. Menemukan lebih sedikit tetapi dengan ketepatan tinggi adalah pilihan yang sah, terutama bila hasilnya akan dipakai untuk penguraian spektral, di mana piksel yang salah masuk merusak campuran yang diuraikan. Yang penting adalah pilihan itu **disadari dan dilaporkan**, bukan disembunyikan di balik satu angka F1.

8.13 Mengapa gabungan (ATAU) lebih baik daripada irisan (DAN)

Bagian 7.7 mencatat temuan yang sekilas berlawanan dengan intuisi: menggabungkan dua masker dengan operasi ATAU (gabungan himpunan) memberi MCC 0,491, sedangkan menggabungkannya dengan DAN (irisan himpunan) hanya memberi MCC 0,171 — lebih buruk daripada masker acak. Mengapa demikian?

Jawabannya terletak pada **seberapa besar kedua masker saling menyetujui**. Kappa antara masker NDVI dan masker fenologi hanya 0,155 — sangat rendah. Artinya kedua masker itu menandai himpunan piksel yang sangat berbeda. Masing-masing menangkap sesuatu yang tidak ditangkap yang lain: NDVI menangkap piksel yang sedang hijau, sedangkan fenologi menangkap piksel yang punya pola tumbuh padi. Keduanya benar, tetapi atas dasar yang berbeda.

Perhatikan akibatnya pada recall. Masker NDVI sendiri menangkap 53,8 persen padi; masker fenologi sendiri menangkap 66,4 persen. Bila keduanya diiriskan — hanya piksel yang **keduanya** sebut padi yang diterima — recallnya jatuh menjadi 32,0 persen. Itu wajar: irisan hanya mempertahankan piksel yang kebetulan disetujui dua metode yang memang jarang setuju, sehingga sebagian besar padi yang hanya tertangkap oleh salah satu metode ikut terbuang. Presisinya memang naik sedikit menjadi 69,5 persen, tetapi kenaikan itu tidak sebanding dengan kehilangan cakupan, dan MCC-nya merosot ke 0,171.

Sebaliknya, ATAU menerima piksel yang disetujui **salah satu** metode. Recallnya melompat menjadi 88,2 persen. Yang menarik, presisinya tidak jatuh — bahkan sedikit naik menjadi 71,9 persen. Mengapa? Karena tambahan piksel yang masuk lewat ATAU sebagian besar adalah padi yang memang tertangkap salah satu metode tetapi terlewat oleh metode lain; piksel itu benar, hanya tidak terdeteksi oleh keduanya sekaligus. Karena itu gabungan menambah benar positif lebih banyak daripada menambah salah positif, dan MCC naik ke 0,491.

Namun prinsip ini **tidak berlaku umum tanpa syarat**, dan penting untuk menyebut syaratnya. Gabungan menguntungkan hanya bila tiga hal dipenuhi. **Pertama**, kedua detektor harus **saling melengkapi**, yaitu kesepakatan antar-keduanya rendah; bila keduanya hampir selalu setuju (kappa tinggi), gabungan tidak menambah apa pun karena himpunannya

hampir sama. **Kedua**, masing-masing detektor harus punya presisi yang cukup baik; bila salah satu detektor sangat banyak salah tuduh, gabungan akan menyeret masuk kesalahan itu dan presisi keseluruhan runtuh. **Ketiga**, tujuannya harus memaksimalkan cakupan — sebagaimana pada pekerjaan ini, di mana membuang piksel padi lebih merugikan daripada memasukkan beberapa piksel bukan padi yang kemudian dapat disaring pada tahap berikutnya. Bila tujuannya justru memperoleh kepastian tinggi pada sedikit piksel, irisan bisa lebih tepat. Jadi aturannya bukan "ATAU selalu lebih baik", melainkan: **untuk detektor yang saling melengkapi dan sama-sama cukup presisi, gabungan lebih baik daripada irisan; untuk detektor yang tumpang tindih (overlap), keduanya setara; dan irisan hanya berguna bila presisi jauh lebih penting daripada cakupan.** Pada data Indramayu, syarat pertama dan kedua terpenuhi — kappa antar-masker 0,155 dan presisi keduanya di atas 60 persen — sehingga gabunganlah yang benar.

Ada pelajaran metodologis di balik ini yang berlaku lebih luas daripada masker padi. Dua sumber informasi yang saling melengkapi hampir selalu lebih baik digabungkan daripada dituntut sepakat. Menuntut sepakat hanya masuk akal bila kedua sumber memang mengukur hal yang sama, sehingga persetujuannya menandakan kepastian. Ketika kedua sumber mengukur hal yang berbeda, tuntutan sepakat justru membuang informasi. Kesalahan yang paling mudah terjadi adalah memakai irisan secara refleks — karena terasa "lebih aman" menuntut dua bukti — padahal pada kasus yang tidak seimbang, kehati-hatian yang salah tempat itu justru menurunkan mutu di bawah garis dasar acak.

8.14 Menentukan ambang MCC untuk pengambilan keputusan

Setelah MCC dapat dihitung, pertanyaan berikutnya bersifat praktis: pada nilai berapa sebuah masker layak dipakai? Jawabannya bergantung pada keputusan yang akan diambilnya, dan karena itu perlu dirumuskan sebagai kebijakan, bukan sekadar angka.

Ingat dulu dua patokan tetap. MCC bernilai 0 pada masker yang tidak membawa informasi, termasuk masker acak dan masker liar. MCC bernilai 1 hanya pada kesepakatan sempurna. Karena itu **ambang terendah yang sah adalah "di atas nol secara berarti"** — cukup untuk membedakan dari kebetulan. Untuk keperluan praktis di laboratorium ini, ambang itu dinaikkan menjadi 0,2, sesuai tafsiran pada 8.6: di bawah 0,2 masker dinilai

tidak berguna. Dengan patokan itu, masker NDVI tunggal (MCC 0,175) berada tepat di bawah ambang dan **tidak layak dipakai sendirian** — sejalan dengan temuan bahwa ia nyaris setara masker acak.

Untuk **memakai** masker sebagai penyaring dalam penguraian spektral, ambang yang dipakai adalah **0,4**, yaitu batas bawah kelas "sedang". Alasannya praktis: masker yang hanya sedikit di atas acak akan memasukkan begitu banyak piksel bukan padi sehingga statistik fraksi menjadi tidak dapat dipercaya. Pada data ini, hanya masker fenologi (0,436) dan masker gabungan (0,491) yang melewati ambang itu; masker NDVI dan irisan tidak. Karena itu keputusan operasional yang diambil adalah memakai gabungan, dengan catatan bahwa masker itu masih berada di ujung bawah kelas sedang.

Untuk **menyatakan** hasil sebagai produk yang dapat dipakai tanpa verifikasi lapangan lebih dahulu, ambangnya jauh lebih tinggi: **0,6**, yaitu batas bawah kelas "kuat". Pada tingkat ini masker sudah membawa informasi yang cukup untuk dipercaya pada tingkat piksel, bukan hanya pada tingkat statistik. Kenyataannya, **tidak ada satu pun masker pada tabel 7.6 yang mencapai 0,6** — nilai tertinggi hanya 0,491. Inilah dasar pernyataan terbuka pada 8.7: seluruh masker pada pekerjaan ini masih berada pada kelas sedang, dan karenanya **belum boleh diandalkan tanpa verifikasi lapangan**. Menyatakan sebaliknya berarti melebih-lebihkan apa yang sebenarnya terukur.

Perlu ditambahkan satu catatan tentang cara memakai ambang ini. Ambang MCC sebaiknya dibaca bersama **selisihnya terhadap garis dasar**, bukan sebagai angka mutlak. Pada data ini, masker gabungan (MCC 0,491) unggul 0,491 di atas acak (0,001) dan 0,316 di atas masker NDVI. Selisih itu yang menunjukkan bahwa penambahan fenologi memang membawa informasi baru. Sebaliknya, irisan (0,171) bahkan berada di bawah masker NDVI tunggal — tanda bahwa operasi itu merugikan, bukan menguntungkan. Dengan membaca ambang dan selisih sekaligus, keputusan menjadi lebih aman: bukan sekadar "lolos ambang", tetapi "lolos ambang karena alasan yang dapat dijelaskan".

8.15 Keterbatasan ESA WorldCover sebagai acuan

Seluruh penilaian pada bab ini bertumpu pada satu asumsi yang belum dibahas terbuka: bahwa ESA WorldCover dapat diperlakukan

sebagai kebenaran acuan. Asumsi itu perlu diperiksa, karena bila acuannya sendiri lemah, maka seluruh angka metrik — sekalipun dihitung dengan rumus yang benar — hanya mengukur kedekatan kepada acuan itu, bukan kedekatan kepada kenyataan.

Keterbatasan pertama adalah **resolusi**. ESA WorldCover disediakan pada resolusi 10 meter, sedangkan masker fenologi pada pekerjaan ini disusun pada grid 250 meter, sejalan dengan resolusi produk MODIS. Perbandingan pada 61.908 piksel grid 250 meter yang mewakili 3.869 kilometer persegi itu berarti setiap piksel acuan merangkum ratusan piksel 10 meter di dalamnya. Bila di dalam satu piksel 250 meter terdapat campuran sawah dan non-sawah — dan pada dataran pantai yang terfragmentasi hal itu sangat lazim — maka kelas tunggal yang diberikan acuan hanyalah kelas yang mendominasi, bukan keadaan seluruh piksel. Ketidakseimbangan yang tercatat sebagai "lahan pertanian 54,9 persen" itu karena itu sendiri sudah merupakan hasil generalisasi, bukan hitungan langsung.

Keterbatasan kedua adalah **tahun dasar**. ESA WorldCover diterbitkan untuk epoch tertentu — versi awalnya mewakili keadaan tahun 2020, dan versi berikutnya tahun

2021. Sementara itu citra yang dianalisis pada pekerjaan ini diambil pada 2026.

Selisih beberapa tahun itu berarti acuan menggambarkan tutupan lahan pada saat yang berbeda dari citra. Pada wilayah dengan alih fungsi lahan yang cepat — dan dataran pantai utara Jawa Barat termasuk wilayah seperti itu — perubahan antara tahun acuan dan tahun citra dapat menimbulkan ketidakcocokan yang **bukan kesalahan masker**, melainkan kesalahan perbandingan. Sebuah piksel yang pada 2021 masih sawah dan pada 2026 sudah menjadi permukiman akan dihitung sebagai salah tuduh oleh masker yang benar, semata karena acuannya sudah usang.

Keterbatasan ketiga, dan yang paling memengaruhi angka pada bab ini, adalah **kelas campuran**. Kelas "cropland" pada ESA WorldCover memuat **seluruh** lahan pertanian — padi, jagung, sayuran, palawija, dan sebagainya — tanpa membedakan jenis tanamannya. Padahal yang dinilai pada bab ini adalah masker **padi**, bukan masker lahan pertanian. Karena itu sebagian dari apa yang dihitung sebagai "benar positif" sesungguhnya adalah tanaman non-padi yang kebetulan berada dalam kelas cropland.

Sebaliknya, sebuah piksel padi yang oleh WorldCover diklasifikasikan sebagai "grassland" atau "shrubland" — kekeliruan yang mungkin terjadi pada sawah berumput muda — akan dihitung sebagai salah tuduh. Kedua arah kesalahan itu menekan nilai metrik ke bawah tanpa mencerminkan mutu masker yang sebenarnya. Inilah salah satu sebab mengapa MCC masker terbaik pada pekerjaan ini hanya 0,491: sebagian penurunan itu berasal dari perbedaan definisi kelas, bukan dari kelemahan masker.

Keterbatasan keempat bersifat lebih mendasar: ESA WorldCover sendiri adalah **produk klasifikasi otomatis**, bukan hasil pengukuran lapangan. Ia memiliki ketidakpastian sendiri, dan pada kelas yang paling penting bagi pekerjaan ini — sawah yang tergenang sebagian — justru termasuk yang paling sulit diklasifikasikan oleh produk semacam itu. Memakai produk yang tidak pasti sebagai kebenaran acuan berarti seluruh metrik pada bab ini hanya sah sampai pada tingkat kepercayaan terhadap acuan itu. Karena itu angka-angka pada tabel 7.6 perlu dibaca dengan bahasa yang tepat: "kesepakatan dengan ESA WorldCover", bukan "akurasi sesungguhnya". Verifikasi lapangan tetap menjadi satu-satunya cara menutup celah ini, dan itulah arah yang akan disinggung pada bab penutup.

Meskipun memiliki keempat keterbatasan itu, ESA WorldCover tetap dipakai, dan alasannya perlu dikatakan. Ia adalah acuan global yang konsisten, tersedia tanpa biaya, dan — yang terpenting untuk penilaian **relatif** — diterapkan sama terhadap semua masker yang dibandingkan. Karena kelemahannya bersifat sistematis dan sama bagi setiap baris tabel, kesimpulan tentang **peringkat** masker (fenologi mengalahkan NDVI, gabungan mengalahkan irisan) tetap sah meskipun nilai absolutnya tidak dapat disebut akurasi sebenarnya. Yang tidak boleh dilakukan adalah mengutip angka 0,491 sebagai "akurasi masker 49 persen" — itu pembacaan yang salah dan melebih-lebihkan makna acuan. Yang benar dikatakan adalah: terhadap acuan yang memiliki keterbatasan yang telah disebut, masker gabungan memberi MCC 0,491, dan itu adalah peringkat terbaik di antara pilihan yang ada pada pekerjaan ini.

9.1 Mengapa alur kerja perlu ditetapkan

Penguraian spektral (spectral unmixing) dapat dijalankan dalam beberapa baris program. Tetapi menjalankan program bukan hal yang sama dengan memperoleh hasil yang dapat dipercaya. Pengalaman pada pekerjaan ini menunjukkan bahwa sebagian besar kesalahan tidak terjadi di dalam algoritme, melainkan pada **pilihan-pilihan sebelum algoritme dijalankan** — endmember (endmember) mana yang dipakai, citra tanggal berapa, piksel mana yang diterima.

Pernyataan itu bukan kesan umum, melainkan kesimpulan yang diperoleh dengan cara yang tidak nyaman. Selama pekerjaan ini berlangsung, berulang kali ditemukan bahwa kode penguraian bekerja persis seperti yang seharusnya. Ia menyelesaikan sistem persamaan, menghormati kendala jumlah-satu dan non-negatif, dan mengembalikan angka yang secara matematis sah — tetapi hasilnya tetap salah. Kesalahan itu tidak ada di dalam solver. Kesalahan itu ada di luar solver. Sumbernya bermacam-macam: citra yang tanggalnya keliru, masker (mask) yang meloloskan objek yang bukan sasaran, kanal (band) yang tidak membawa perbedaan yang dicari, atau satu baris piksel kosong yang menyusup ke dalam larik masukan.

Sebab itu alur kerja disusun lebih dahulu, dengan satu prinsip: **setiap tahap yang memakan biaya besar harus didahului oleh tahap pemeriksaan yang murah**. Kegagalan paling murah adalah kegagalan yang terdeteksi paling awal. Mengunduh satu petabyte citra, lalu menemukan bahwa sensornya tidak punya kanal red-edge, adalah pemborosan. Beberapa detik memeriksa metadata sudah cukup untuk menghindarinya. Menjalankan solver dua juta piksel selama ratusan detik, lalu menemukan bahwa larik masukannya berisi nilai kosong, juga pemborosan. Satu baris memeriksa sudah cukup untuk menghindarinya.

Alur kerja yang dipakai terdiri dari enam tahap. Urutannya bukan sembarang urutan. Bab ini menjelaskan setiap tahap beserta alasan mengapa ia berada di posisi itu. Untuk tiap tahap, bab ini juga menyebutkan hal yang lebih berguna daripada teori: **perintah dan parameter konkret yang dipakai, biaya waktu dan penyimpanan yang ditimbulkan, cara memastikan tahap itu sudah benar sebelum melangkah, dan kasus**

kegagalan nyata yang pernah terjadi. Alasan menuliskan hal-hal teknis semacam itu adalah agar pembaca berikutnya tidak perlu menempuh jalan yang sama untuk menemukan bahwa sebuah tahap belum benar.

9.2 Ringkasan alur kerja

1. PILIH ENDMEMBER
SpecLib ITS (5 kelas padi). Dipakai apa adanya – tidak diskalakan.
↓
2. UJI ENDMEMBER
Rasio singular (singular-value ratio) · jarak antar kelas · matriks kekeliruan (confusion matrix) piksel murni (pure pixel).
Bila akurasi < 85%: hentikan, jangan lanjut.
↓
3. PILIH SENSOR
Sentinel-2 MSI (3 kanal red-edge) – minimum untuk pemisahan varietas (variety).
↓
4. TENTUKAN JENDELA TANGGAL
Unduh MODIS tahun tanam yang sama → hitung tanggal pembungaan (flowering) per piksel → ambil persentil (percentile) 25–75 sebagai jendela → unduh S2 pada jendela itu.
↓
5. PISAHKAN PADI DAN NON-PADI
NDVI > 0,35 DAN NDWI < 0 DAN SCL sah.
Diperkuat fenologi (phenology): ada genangan (NDFI ≥ 0,10), durasi musim (season) 60–150 hari, puncak EVI ≥ 0,35.
↓
6. LSU PADA PIXEL PADI
FCLS tervektor. Endmember apa adanya.
Laporkan fraksi (fraction) + tingkat pencampuran piksel.

Diagram di atas sengaja dibaca sebagai urutan yang tidak boleh ditukar. Setiap anak panah menandakan satu hal: keluaran tahap sebelumnya menjadi masukan tahap berikutnya, sedangkan keputusan pada tahap berikutnya bergantung pada hasil tahap sebelumnya. Tahap 2 menguji bahan yang dipilih pada tahap 1; tahap 4 mengunduh citra dari sensor yang ditetapkan pada tahap 3; tahap 6 menguraikan hanya piksel yang lolos tahap 5. Bila salah satu tahap dilangkahi, tahap berikutnya kehilangan dasar keputusannya.

9.3 Tahap 1 — Memilih endmember

Tahap pertama tampak sepele, tetapi menentukan seluruh hasil. Endmember yang dipilih harus mewakili kelas yang benar-benar ingin dipetakan, serta harus tersedia untuk kanal-kanal sensor yang akan dipakai.

Pada pekerjaan ini, endmember diambil dari basis data Speclib yang dikelola laboratorium, berisi lima kelas varietas padi: Ciherang, IR64, Inpari32, Inpari32_WBC, dan Mekongga. Setiap spektrum merupakan hasil pengukuran spektoradiometer yang direduksi menjadi sembilan kanal Sentinel-2 menggunakan metode reduksi median dan pemetaan kanal Gaussian.

Secara teknis, basis data itu disimpan sebagai berkas JSON di dalam direktori `emsensor/`, dengan satu berkas per sensor — untuk pekerjaan ini berkas `Sentinel-2_MSI.json`. Sembilan kanal yang dipakai adalah B1 443 nm, B2 490 nm, B3 560 nm, B4 665 nm, B5 705 nm, B6 740 nm, B7 783 nm, B8 842 nm, dan B9 865 nm. Perhatikan bahwa ketiga kanal red-edge — B5, B6, dan B7 — berada tepat di dalam daftar itu; itulah alasan sensor ini dipilih, sebagaimana dibahas pada Bab 6. Membaca berkas itu dan memeriksa panjang vektornya adalah langkah termurah yang dapat dilakukan. Bila panjang vektornya bukan sembilan, berarti pemetaan kanal belum benar, dan seluruh tahap berikutnya akan bekerja pada spektrum yang keliru.

Satu keputusan penting diambil pada tahap ini — keputusan itu akan dibahas panjang pada Bab 12: **endmember dipakai apa adanya, tanpa penskalaan**. Keputusan ini lahir setelah uji menunjukkan bahwa penskalaan — dalam bentuk apa pun — menurunkan akurasi pemisahan, meskipun angka galatnya membaik. Endmember Speclib memiliki nilai inframerah dekat antara 0,5927 (Inpari32) dan 0,8464 (Inpari32_WBC); angka-angka itu dibiarkan apa adanya, tidak dibagi seratus, tidak dikalikan faktor, tidak dikoreksi per kanal.

Cara memastikan tahap ini sudah benar ada tiga. Ketiganya murah. Pertama, jumlah kelas harus lima, sesuai varietas yang ingin dipetakan. Kedua, setiap spektrum harus memiliki sembilan nilai, sesuai kanal Sentinel-2. Ketiga, tidak boleh ada nilai kosong pada larik endmember; satu nilai kosong akan merambat ke seluruh tahap 6 tanpa peringatan.

Pemeriksaan ketiga itu memakai fungsi isfinite pada larik endmember; hasilnya harus benar untuk seluruh elemen.

Basis data endmember perlu dipelihara sebagai aset laboratorium. Setiap kali endmember baru ditambahkan, ia harus melewati uji pada tahap 2 sebelum dipakai. Tanpa disiplin itu, basis data akan terisi spektrum yang tidak dapat dipisahkan; pengguna berikutnya akan memperoleh hasil yang buruk tanpa mengetahui sebabnya. Kasus kegagalan yang paling sering terjadi pada tahap ini bukanlah kesalahan hitung, melainkan pencampuran satuan: endmember yang seharusnya dalam skala reflektansi (reflectance) 0–1 tetapi tersimpan dalam skala 0–10.000, atau sebaliknya. Bila itu terjadi, jarak antar-kelas akan membengkok atau menyusut tanpa alasan yang jelas; uji pada tahap 2 pun akan gagal dengan cara yang membingungkan. Sebab itu, sebelum melangkah, skala endmember harus berada pada rentang 0–1.

9.4 Tahap 2 — Menguji endmember sebelum memproses

Inilah tahap yang paling sering dilewati, padahal ia yang paling menghemat waktu. Tujuannya sederhana: mengetahui lebih dahulu apakah endmember yang dipilih mampu memisahkan kelas-kelasnya, sebelum memproses citra yang besar.

Ada tiga pengujian. Ketiganya murah.

Rasio singular mengukur kestabilan geometri endmember. Nilai yang sangat besar menandakan ada arah pemisah yang sangat tipis, sehingga solusinya rapuh terhadap derau (noise). Pada data ini, rasio singular untuk sembilan kanal Sentinel-2 adalah 410,8 — sebuah nilai yang wajar. Sebagai pembanding, rasio singular yang sama dihitung pada empat kanal Landsat memberi 79,4. Angka yang lebih kecil pada Landsat **tidak** berarti Landsat lebih baik; sebagaimana dijelaskan pada Bab 6, rasio singular mengukur kestabilan solusi, sedangkan yang menentukan kemampuan memisahkan adalah jarak antar-kelas. Kedua ukuran itu harus dibaca bersama, bukan salah satu saja.

Jarak spektral (spectral distance) antar kelas mengukur seberapa berbeda dua spektrum. Yang penting bukan nilai absolutnya, melainkan perbandingannya dengan derau citra. Jarak yang hanya beberapa kali derau tidak dapat diandalkan. Pada data ini, pasangan terdekat adalah Ciherang–IR64 dengan jarak 0,1222; pasangan terjauh adalah Inpari32–Inpari32_WBC dengan jarak 1,1027. Derau reflektansi permukaan

Sentinel-2 berada pada orde 0,010, sehingga jarak 0,1222 setara dengan sekitar dua belas kali derau — cukup untuk dipisahkan, tetapi tidak lega.

Matriks kekeliruan pada piksel murni adalah uji yang paling menentukan. Piksel sintetis dibangkitkan dari setiap spektrum endmember, ditambah derau pada tingkat yang realistis, lalu diuraikan kembali. Bila algoritme tidak dapat mengenali kembali spektrum yang dibangkitkan dari endmember itu sendiri, tidak ada alasan mengharapkan hasil yang baik pada citra nyata. Pelaksanaannya sederhana: untuk setiap varietas, dibangkitkan sejumlah piksel uji dari spektrumnya, ditambahkan derau Gaussian dengan simpangan baku 0,010, lalu dijalankan penguraian, kemudian diperiksa kelas mana yang memperoleh fraksi tertinggi. Perbandingan antara kelas hasil dan kelas asal itulah matriks kekeliruannya.

Pada data ini, uji itu memberi akurasi 91,1 persen pada derau 0,010, dengan rincian: Ciherang 100 persen, IR64 59,7 persen, Inpari32 96,1 persen, Inpari32_WBC 100 persen, dan Mekongga 100 persen. Pada derau nol, akurasi 100 persen dengan galat 0,0000 — yang membuktikan bahwa implementasi algoritmanya benar, dan bahwa yang membatasi akurasi adalah derau citra, bukan kodenya.

Angka IR64 sebesar 59,7 persen adalah temuan yang penting. Ia menunjukkan bahwa IR64 tidak dapat dipisahkan secara andal dari Ciherang — 28,9 persen piksel IR64 justru dikenali sebagai Ciherang, sedangkan 11,4 persen dikenali sebagai Inpari32. Penyebabnya adalah jarak spektral keduanya yang hanya 0,1222, terpendek di antara seluruh pasangan.

Ambang (threshold) henti. Bila akurasi pemisahan berada di bawah 85 persen, pekerjaan sebaiknya dihentikan pada tahap ini; endmember pun ditinjau kembali. Melanjutkan hanya akan menghasilkan peta yang tidak dapat dipertanggungjawabkan, dengan biaya waktu yang jauh lebih besar.

Cara mengetahui tahap ini sudah benar adalah dengan memperhatikan dua hal sekaligus. Pertama, pada derau nol, akurasi harus tepat 100 persen dengan galat nol; bila tidak, yang bermasalah adalah implementasi, bukan data. Kedua, pada derau realistis, akurasi total harus berada di atas ambang 85 persen. Kedua pemeriksaan itu harus berjalan bersamaan, karena keduanya menguji hal yang berbeda: yang pertama

menguji kebenaran kode, yang kedua menguji kelayakan data. Kasus kegagalan yang pernah terjadi pada tahap ini bersifat halus: seluruh kelas memperoleh akurasi tinggi kecuali satu; kehadiran satu kelas yang buruk itu menurunkan akurasi total hingga mendekati ambang. Bila total 91,1 persen dilihat sekilas, tampaknya semuanya baik; tetapi setelah dirinci per kelas, tampak bahwa satu varietas — IR64 — berada pada 59,7 persen. Pelajaran yang diambil: **jangan hanya melihat angka total; periksa setiap baris matriks kekeliruan**. Angka total dapat menyembunyikan satu kelas yang gagal total.

9.4.1 Koreksi atmosfer: langkah yang tidak boleh dilewati

Satu langkah sering dilewati sebelum endmember diuji. Akibatnya seluruh uji pada tahap ini kehilangan maknanya. Langkah itu adalah **koreksi atmosfer**.

Alasannya sederhana tetapi mudah terlewat: endmember SpecLib diukur di permukaan tanah, sedangkan citra satelit yang belum dikoreksi masih memuat pengaruh atmosfer. Keduanya belum berada pada satuan yang sama, sehingga membandingkannya berarti membandingkan dua hal yang berbeda. Pada uji WorldView-2 yang dilaporkan pada bagian 13.6.2, koreksi atmosfer menurunkan jarak spektral ke endmember terdekat dari 0,2386 menjadi 0,0902 — hampir tiga kali lebih dekat — serta membuat kanal merah cocok hampir sempurna.

Perlu diperhatikan satu jebakan penamaan. Produk WorldView-2 dengan tingkat LV2A dan penanda ORStandard2A sering dibaca sebagai "level 2" dalam arti reflektansi permukaan. Yang dimaksud sebenarnya adalah *Ortho Ready Standard 2A*: citra sudah dikoreksi secara radiometrik dan geometrik, tetapi **atmosfer belum dikoreksi**. Jadi meskipun namanya memuat angka 2, datanya masih reflektansi puncak atmosfer.

Koreksi dapat dijalankan dengan model 6S [19], yang memerlukan beberapa parameter masukan: sudut zenith matahari, kadar uap air, ozon, dan kedalaman optik aerosol (AOD). Pada pekerjaan ini koreksi dijalankan dengan perangkat **6S Natural** yang dikembangkan laboratorium [21], yang menghitung koefisien tiap kanal dari parameter masukan tersebut. Di antara keempat parameter itu, **AOD adalah yang paling menentukan dan paling sering diisi dengan nilai bawaan**. Pada adegan yang sama, uji kepekaan memberi hasil berikut:

AOD yang dipakai	Piksel yang cocok dengan endmember
0,10	45,8 persen
0,20 (nilai bawaan)	41,1 persen
0,35	11,0 persen
0,50	0,1 persen

Rentangnya ekstrem: dari AOD 0,20 ke 0,50, kecocokan endmember runtuh dari 41,1 persen menjadi 0,1 persen. Sebab itu **AOD tidak boleh dibiarkan pada nilai bawaan**. Ia harus diambil dari data terukur, misalnya dari jaringan AERONET pada stasiun terdekat dan pada tanggal akuisisi. Pada adegan ini, nilai AERONET terukur berbeda 6,1 persen dari nilai bawaan — perbedaan yang kebetulan kecil, tetapi tidak dapat diandalkan untuk adegan lain.

Satu peringatan penutup. Koreksi atmosfer yang lebih baik **tidak menjamin** penguraian yang lebih baik. Pada adegan yang sama, koreksi memperbaiki galat rekonstruksi dari 0,4669 menjadi 0,3603 dan menurunkan fraksi negatif dari 37,7 persen menjadi 29,8 persen, tetapi 100 persen piksel tetap melanggar kendala non-negatif. Artinya, koreksi atmosfer adalah syarat perlu, bukan syarat cukup: ia menghilangkan satu sumber ketidakcocokan, tetapi tidak menyelesaikan ketidakcocokan yang berasal dari perbedaan skala antara endmember kanopi dan piksel yang memuat banyak benda.

9.5 Tahap 3 — Memilih sensor

Cara memilih sensor dibahas rinci pada Bab 6. Yang perlu ditegaskan di sini adalah bahwa sensor harus dipilih **sebelum** mengunduh citra, karena mengunduh dan memproses citra dari sensor yang tidak memadai adalah pemborosan yang besar.

Kriterianya bersifat teknis: sensor harus memiliki kanal pada daerah **red-edge**, karena di situlah perbedaan antar-varietas padi paling terlihat. Sentinel-2 memiliki tiga kanal di daerah itu; Landsat tidak memiliki satu pun.

Konsekuensinya tegas. Pada uji, Landsat memangkas jarak antar-varietas menjadi sekitar separuh — pasangan Ciherang–IR64 turun dari 0,1222 menjadi 0,0610, Ciherang–Inpari32 turun dari 0,1595 menjadi

0,0709, serta IR64—Mekongga turun dari 0,2140 menjadi 0,1162. Dengan jarak sekecil itu, pemisahan tidak dapat diandalkan.

Cara memastikan tahap ini sudah benar adalah dengan memeriksa daftar panjang gelombang sensor sebelum mengunduh apa pun. Pemeriksaan itu cukup memakai metadata sensor, dan hasilnya harus memperlihatkan kanal di sekitar 705 nm, 740 nm, dan 783 nm. Bila salah satu dari ketiganya tidak ada, sensor itu tidak layak dipakai untuk pemisahan varietas. Kasus kegagalan pada tahap ini adalah pemborosan yang paling mudah dihindari, tetapi paling mahal bila terjadi. Bayangkan menjalankan seluruh alur pada citra Landsat, menyelesaikan semua tahap, lalu menemukan di akhir bahwa jarak antar-varietas menyusut separuh, tanpa satu pun kanal red-edge. Seluruh pekerjaan itu harus dibuang, bukan karena ada yang salah dalam pengerjaannya, melainkan karena sensor yang dipilih sejak awal memang tidak memadai. Sebab itu sensor ditempatkan pada tahap ketiga — cukup awal untuk mencegah pemborosan, tetapi setelah endmember dipastikan dapat dipisahkan.

9.6 Tahap 4 — Menentukan jendela tanggal

Tahap ini adalah tahap yang paling sering diabaikan; pada pekerjaan ini justru menjadi sumber kesalahan yang paling besar.

Alasannya bersifat fisik. Sawah menempuh siklus penuh dalam satu musim tanam (cropping season): tanah digarap, digenangi, ditanami, tumbuh, berbunga, menguning, lalu dipanen. Sepanjang siklus itu, spektrumnya berubah sangat banyak — jauh **melebihi perbedaan antar-varietas** yang ingin kita ukur.

Bila citra yang dianalisis memuat sawah pada berbagai fase sekaligus, variasi fase itu akan menutupi perbedaan varietas. Endmember yang mewakili padi pada fase tertentu hanya akan cocok untuk sebagian piksel.

Sebab itu jendela tanggal harus ditentukan dari fenologi, bukan dari tanggal sembarang. Prosedurnya:

1. Unduh data MODIS MOD13Q1 untuk **tahun tanam yang sama** dengan citra yang akan dianalisis.
2. Hitung puncak EVI setiap piksel; puncak itu bertepatan dengan pembungaan.

3. Ambil persentil 25 sampai 75 dari sebaran tanggal pembungaan sebagai jendela.
4. Unduh citra Sentinel-2 pada jendela itu, kuantifikasi, dan saring awan.

Secara teknis, langkah pertama dijalankan dengan mengunduh produk MODIS/061/MOD13Q1 pada resolusi 250 meter dan selang waktu 16 hari. Untuk pekerjaan ini, periode yang diunduh adalah 14 September 2025 sampai 29 Agustus 2026, menghasilkan 23 observasi. Sebelum dipakai, mutu data disaring melalui kanal *DetailedQA*, khususnya dua bit pertama yang menyatakan mutu indeks vegetasi; hanya observasi bermutu baik atau marjinal yang dipertahankan. Hasilnya sekitar 52 persen observasi lolos — angka yang wajar untuk daerah tropis dengan tutupan awan tinggi. Setiap deret waktu (time series) yang lolos kemudian dihaluskan dengan tapis Savitzky–Golay dua iterasi, lalu puncaknya ditentukan sebagai tanggal pembungaan piksel itu.

Pada data ini, jendela yang benar adalah **24 Februari sampai 3 Mei 2026**, dengan tanggal pembungaan median 22 Maret 2026. Rentang itu diambil dari persentil 25 tanggal pembungaan (6 Maret 2026) sampai persentil 75 (23 April 2026), diperlebar secukupnya agar mencakup seluruh fase puncak.

Cara mengetahui tahap ini sudah benar adalah dengan memeriksa tiga hal. Pertama, durasi musim yang terukur harus wajar untuk padi Indonesia — pada data ini nilai tengahnya 92 hari, dengan persentil 25 sebesar 79 hari dan persentil 75 sebesar 110 hari. Bila durasi yang terukur jauh lebih panjang atau lebih pendek, berarti kurva yang tertangkap bukan kurva padi. Kedua, jendela yang dipilih harus memuat sebagian besar tanggal pembungaan — pada data ini sekitar separuh sawah berbunga paling serentak di dalam jendela itu. Ketiga — dan ini yang paling penting — jendela yang dipakai harus diperiksa terhadap tanggal pembungaan median, bukan terhadap tanggal kalender. Pemeriksaan ketiga itu murah dan menentukan.

Satu catatan yang perlu disampaikan secara terbuka: pada analisis awal, jendela yang dipakai adalah 1 Mei sampai 31 Agustus 2026 — yang **mulai 39 hari setelah** pembungaan median. Akibatnya komposit (composite) itu memuat 0,0 persen piksel padi pada fase puncak. Ketika fase setiap piksel padi ditentukan untuk jendela itu, hasilnya: 32,4 persen

berada pada fase bera (fallow) atau persiapan, 64,5 persen pada fase vegetatif, 1,1 persen pada fase generatif, dan hanya 0,0 persen pada fase puncak. Hanya 29,9 persen piksel yang puncak EVI-nya jatuh di dalam jendela komposit. Ini kesalahan yang nyata,

Sebaran kelas fase di atas dihitung dengan membandingkan EVI rata-rata di dalam jendela terhadap kurva penuh. Cara itu tidak stabil terhadap pergeseran jendela — kelasnya berubah pada 56,8 sampai 71,4 persen piksel ketika jendela digeser 20 sampai 40 hari — sedangkan kelas puncaknya praktis kosong. Angka itu tetap sah sebagai bukti bahwa jendela lama duduk pada fase yang salah. Tetapi bila sebaran kelas fase hendak dipakai menarik kesimpulan agronomis, angka itu harus dihitung ulang dari tanggal yang diturunkan dari puncak EVI (Bab 15.8). dan Bab 11 membahas akibatnya. Kesalahan itu terjadi bukan karena hitungan yang rumit, melainkan karena jendela tanggal dipilih tanpa membandingkannya terlebih dahulu dengan tanggal pembungaan median. Satu perbandingan sederhana — "apakah jendela ini memuat Maret 2026?" — sudah cukup untuk mencegahnya.

9.7 Tahap 5 — Memisahkan padi dan non-padi

Tahap ini dibahas rinci pada Bab 8. Yang perlu ditegaskan di sini adalah **mengapa tahap ini berada di posisi kelima**, bukan lebih awal.

Alasannya: penguraian spektral pada dasarnya menguraikan campuran. Bila campuran yang diuraikan mencakup air, tanah, dan bangunan, hasilnya akan didominasi oleh bahan-bahan yang bukan sasaran. Fraksi padi akan tertekan oleh bahan lain yang tidak ada dalam daftar endmember. Sebagaimana dibahas pada Bab 2, piksel yang berada di luar hull akan menghasilkan solusi sudut yang tidak bermakna.

Dengan menyaring lebih dahulu, penguraian hanya bekerja pada objek yang benar.

Secara teknis, masker dibangun dari tiga syarat yang harus terpenuhi sekaligus. Syarat pertama adalah **mutu data**: kanal *Scene Classification Layer* pada Sentinel-2 memberi kelas untuk setiap piksel, dan hanya kelas yang sah yang diterima — vegetasi, bukan vegetasi, air, serta tak terklasifikasi; piksel yang tertutup awan atau bayangannya langsung disingkirkan. Syarat kedua adalah **bukan air**: NDWI dihitung dari kanal hijau dan inframerah dekat; piksel dengan NDWI positif disingkirkan.

Syarat ketiga adalah **bervegetasi**: NDVI harus melebihi 0,35. Ketiga syarat digabungkan; hasilnya adalah masker padi awal. Pada data Indramayu, masker ini menerima 1.994.687 piksel dari 4.276.094 piksel sah — atau 46,6 persen.

Masker itu kemudian diperkuat dengan analisis fenologi multi-temporal. Sebuah piksel hanya diterima sebagai padi bila ia juga menunjukkan pola pertumbuhan yang khas padi: puncak EVI minimal 0,35, durasi musim antara 60 dan 150 hari, dan bukti genangan dengan NDFI maksimum minimal 0,10. Penguatan ini membuang 44,9 persen piksel dari masker awal, menyisakan 1.099.658 piksel.

Cara mengetahui tahap ini sudah benar bukanlah dengan melihat F1, karena F1 menyesatkan pada kelas yang tidak seimbang — sebagaimana dibahas pada Bab 8. Ukuran yang benar adalah MCC dan kappa. Pada data ini, masker NDVI tunggal memberi MCC 0,175, masker fenologi MODIS memberi MCC 0,436, sedangkan gabungan keduanya memberi MCC 0,491 dengan recall 88,2 persen. Selain itu, dua pembanding harus selalu disertakan: masker "liar" yang menjawab "semua padi" serta masker acak. Pada data ini, masker liar (naive mask) memperoleh F1 70,9 persen meskipun MCC-nya tepat nol — bukti bahwa F1 tidak dapat dipercaya di sini.

Kasus kegagalan nyata pada tahap ini, dan ini yang paling berbahaya karena tidak menimbulkan pesan galat, adalah **kanal SCL yang ikut terbagi sepuluh ribu**. Berkas Sentinel-2 Level-2A menyimpan kanal reflektansi dalam bilangan bulat yang harus dibagi 10.000 untuk memperoleh reflektansi 0–1. Bila langkah pembagian itu diterapkan seragam pada seluruh berkas — termasuk pada kanal SCL yang seharusnya berupa kelas diskret 0 sampai 11 — maka nilai SCL yang semula 4 (vegetasi) atau 8 (awan berpeluang sedang) berubah menjadi 0,0004 atau 0,0008. Akibatnya seluruh perbandingan seperti "SCL sama dengan 8" tidak pernah terpenuhi; masking awan pun **gagal total**: bukan karena kodenya salah, tetapi karena nilai yang dibandingkan sudah tidak lagi berupa kelas. Kegagalan itu sunyi. Masker yang dihasilkan tampak wajar, jumlah pikselnya masuk akal, tanpa peringatan apa pun; yang hilang hanyalah kemampuan menyaring awan, sehingga piksel berawan ikut masuk ke penguraian. Cara mencegahnya sederhana: sebelum dipakai, kanal SCL harus diperiksa nilainya; nilai yang muncul harus berupa

bilangan bulat antara 0 dan 11 — bukan pecahan. Bila yang muncul adalah pecahan, berarti pembagian oleh 10.000 telah dikenakan pada kanal yang salah.

Ada satu hal lagi yang perlu dipahami dengan tepat — hal ini dibahas pada Bab 8: **memperbaiki masker tidak memperbaiki fraksi**. Masker hanya memilih subset piksel. Yang diperbaiki oleh masker yang lebih baik adalah cakupan yang lebih wajar serta kepercayaan yang lebih tinggi, bukan angkanya. Ketika fraksi dihitung ulang pada himpunan piksel yang sama untuk kedua masker, hasilnya identik sampai empat angka desimal.

9.8 Tahap 6 — Menjalankan penguraian

Tahap terakhir adalah menjalankan FCLS pada piksel padi yang sudah disaring.

Dua hal teknis perlu diperhatikan. **Pertama**, implementasi yang dipakai adalah versi tervektor, yang menyelesaikan penguraian 1,99 juta piksel dalam waktu sekitar 14 detik — dibandingkan orde menit untuk implementasi per piksel. Perbandingan yang diukur langsung: implementasi per piksel pada satu scene memerlukan 276 sampai 360 detik, sedangkan implementasi tervektor NumPy menyelesaikannya dalam 0,12 detik — sekitar 2.653 kali lebih cepat. Selisih hasil antara kedua implementasi itu kecil untuk sebagian besar piksel — rata-rata 0,00083 dan persentil 95 sebesar 0,00237. Namun terdapat selisih maksimum sebesar 1,000000, yang berasal dari perbedaan antara pemotongan dan normalisasi dengan penyelesaian kuadrat terkecil tak-negatif sejati. Perbedaan itu perlu disadari agar tidak menimbulkan kejutan ketika dua implementasi dibandingkan. **Kedua**, sebelum menjalankan solver, pastikan tidak ada nilai kosong pada data. Pada uji ini ditemukan bahwa satu baris sambungan mosaik yang kosong — hanya 771 piksel dari 1,99 juta — menyebabkan solver mengembalikan nilai kosong pada **seluruh** larik hasilnya. Pemeriksaan sederhana dengan `isfinite` mencegah kegagalan yang membingungkan.

Kasus 771 piksel itu perlu diceritakan lebih lengkap karena ia mengajarkan sesuatu yang tidak dapat dipelajari dari teori. Larik masukan berisi sekitar dua juta piksel, dan di dalamnya terdapat satu baris tipis yang seluruh nilainya kosong — sisa dari sambungan mosaik yang tidak tertutup oleh citra mana pun. Secara proporsi, baris itu hanya 0,04 persen dari

seluruh data; sebagian besar orang akan menganggapnya tidak berarti. Tetapi ketika larik itu diserahkan kepada solver, operasi matriksnya bekerja pada seluruh larik sekaligus, bukan piksel demi piksel. Satu nilai kosong menyebar melalui operasi matriks itu; hasilnya adalah larik keluaran yang **seluruhnya** kosong — dua juta piksel yang seharusnya berisi fraksi kembali sebagai nol nilai. Kegagalannya bukan sebagian, melainkan menyeluruh; penyebabnya adalah 771 piksel yang tidak terlihat. Inilah alasan mengapa pemeriksaan isfinite ditempatkan **sebelum** solver dijalankan, bukan sesudahnya. Pemeriksaan itu murah — satu pemanggilan fungsi — dan menutup satu kelas kegagalan yang paling membingungkan karena gejalanya tidak sebanding dengan sebabnya.

Hasil tahap ini dilaporkan sebagai fraksi per varietas, disertai dua penanda kepercayaan: **RMSE relatif** dan **persentase piksel ekstrem (extreme pixel)**. Penanda kedua justru lebih penting daripada yang pertama, sebagaimana dijelaskan pada Bab 13. Pada komposit jendela lama, RMSE relatif 166,0 persen dengan piksel ekstrem 0,004 persen; pada komposit jendela pembungaan, RMSE relatif 155,7 persen dengan piksel ekstrem 3,815 persen. Kedua angka ini dihitung pada komposit yang telah dirata-ratakan, sehingga tidak sama dengan RMSE penguraian penuh yang dilaporkan pada Bab 12 dan Bab 13; keduanya mengukur hal yang berbeda dan tidak boleh dipertukarkan. Perhatikan bahwa RMSE turun sementara piksel ekstrem naik hampir seribu kali — kenaikan piksel ekstrem itulah yang mencegah kesimpulan terlalu cepat bahwa jendela baru lebih baik.

Cara mengetahui tahap ini sudah benar adalah dengan tiga pemeriksaan. Pertama, tidak boleh ada nilai kosong pada larik masukan, dan itu diperiksa dengan isfinite. Kedua, jumlah piksel keluaran harus sama dengan jumlah piksel masukan; bila berbeda, berarti ada piksel yang hilang dalam proses. Ketiga, persentase piksel ekstrem harus dilaporkan, karena penanda itulah yang menyatakan apakah solusi terdorong ke batas. Solusi yang sehat memiliki piksel ekstrem di bawah satu persen; bila angkanya jauh lebih tinggi, berarti endmember tidak mencakup piksel yang diuraikan; hasilnya pun tidak layak dipakai tanpa catatan.

9.9 Mengapa urutan ini penting

Urutan enam tahap di atas dirancang dengan satu logika: **saring dan uji sebelum memproses**.

Tahap 2 mencegah pemrosesan dengan endmember yang tidak memadai. Tahap 3 mencegah pengunduhan citra dari sensor yang salah. Tahap 4 mencegah analisis pada citra dengan fase yang keliru. Tahap 5 mencegah penguraian pada objek yang bukan sasaran.

Bila urutannya dibalik — misalnya mengunduh citra lebih dahulu lalu mencari endmember yang cocok — biaya yang dikeluarkan jauh lebih besar, tetapi hasilnya tidak lebih baik. Pada pekerjaan ini, pelajaran itu diperoleh dengan cara yang tidak nyaman: sebuah analisis lengkap dijalankan pada citra dengan jendela tanggal yang salah; seluruh hasilnya harus ditinjau ulang setelah kesalahan itu ditemukan.

Logika yang sama berlaku di dalam setiap tahap, bukan hanya di antara tahap. Pada tahap 4, MODIS diunduh sebelum Sentinel-2, karena MODIS jauh lebih kecil dan menentukan tanggal yang harus diunduh. Pada tahap 5, masker murah dihitung lebih dahulu — NDVI dan NDWI hanya memerlukan dua kanal — sebelum masker fenologi yang lebih mahal. Pada tahap 6, *isfinite* diperiksa sebelum solver, bukan sesudahnya. Polanya konsisten di setiap tingkat: yang murah mendahului yang mahal; yang mahal hanya dijalankan setelah yang murah memberi izin.

9.10 Ringkasan

Tahap	Tujuan	Kriteria henti
1. Pilih endmember	Menetapkan kelas yang dipetakan	—
2. Uji endmember	Memastikan kelas dapat dipisahkan	Akurasi < 85% → berhenti
3. Pilih sensor	Memastikan kanal memadai	Tanpa red-edge → berhenti
4. Tentukan jendela	Menghindari pencampuran fase	Tanpa data fenologi → jangan menebak
5. Pisahkan padi	Menyaring objek sasaran	—
6. Jalankan LSU	Memperoleh fraksi	Laporkan piksel ekstrem

Tiga kriteria henti pada tabel itu bukan formalitas. Masing-masing mewakili kesalahan yang sudah pernah terjadi; masing-masing akan menghemat waktu yang besar bila dipatuhi.

9.11 Biaya waktu dan penyimpanan tiap tahap

Bagian ini mencatat biaya setiap tahap, karena pengetahuan tentang biaya itulah yang menentukan mengapa pemeriksaan murah ditempatkan paling awal. Angka-angka di bawah berasal dari pengukuran pada pekerjaan ini.

Tahap 1 dan tahap 2 nyaris tidak memakan biaya komputasi. Membaca basis data endmember hanya melibatkan sebuah berkas JSON berukuran beberapa kilobita. Menjalankan tiga uji endmember hanya melibatkan larik berukuran 5×9 — jauh lebih kecil daripada sebuah citra. Biaya keduanya berada pada orde milidetik sampai detik. Inilah yang membuat tahap 2 begitu berharga: ia dapat menghentikan pekerjaan yang salah sebelum satu byte citra pun diunduh.

Tahap 3 tidak memakan biaya komputasi sama sekali; yang dibutuhkan hanya membaca metadata sensor. Tetapi keputusan yang diambil di sini menentukan biaya tahap berikutnya. Memilih Sentinel-2 berarti mengunduh sembilan kanal pada resolusi 30 meter untuk area kajian seluas $76,6 \times 49,8$ kilometer, yang tersusun pada grid 1.671×2.561 piksel. Memilih sensor dengan lebih banyak kanal berarti mengunduh lebih banyak data lagi.

Tahap 4 adalah tahap dengan rasio manfaat terhadap biaya yang paling tinggi. Data MODIS MOD13Q1 yang diunduh berukuran 250 meter dengan selang 16 hari, sehingga seluruh 23 observasi untuk area kajian berukuran jauh lebih kecil daripada satu scene Sentinel-2 saja. Mengunduh MODIS berada pada orde puluhan megabita, sedangkan mengunduh Sentinel-2 berada pada orde ratusan megabita sampai gigabita. Artinya, tahap yang paling menentukan jendela tanggal justru adalah tahap yang paling murah — itulah alasan mengapa tidak ada pembenaran untuk melewatinya. Kesalahan pada tahap 4, sebagaimana yang pernah terjadi, memaksa seluruh tahap berikutnya dijalankan dua kali.

Tahap 5 memakan biaya komputasi yang moderat, karena masker dihitung per piksel pada 4.276.094 piksel sah. Tetapi biaya itu masih jauh lebih kecil daripada biaya tahap 6; hasilnya menyusutkan jumlah piksel yang harus diuraikan menjadi 1.994.687. Menyaring lebih dahulu berarti tahap termahal hanya bekerja pada separuh data.

Tahap 6 adalah tahap dengan biaya terbesar; sebab itu ia diletakkan paling akhir. Menjalankan FCLS tervektor pada 1,99 juta piksel memerlukan sekitar 14 detik. Bila implementasi per piksel yang dipakai, biaya yang sama memerlukan 276 sampai 360 detik per scene — perbedaan yang cukup besar untuk menentukan apakah sebuah eksperimen dapat diulang puluhan kali atau tidak. Penyimpanan yang dihasilkan tahap ini pun paling besar: setiap piksel padi menghasilkan lima nilai fraksi, ditambah penanda kepercayaan; keluarannya berupa larik sebesar jumlah piksel padi dikalikan jumlah kelas.

Pelajaran yang dapat ditarik dari daftar biaya ini bukanlah angka-angkanya, melainkan hubungannya: tahap-tahap termurah adalah tahap-tahap yang paling menentukan; tahap-tahap termahal adalah tahap-tahap yang paling akhir. Alur kerja ini disusun agar kesalahan terdeteksi pada saat biayanya masih kecil.

9.12 Memeriksa data sebelum diproses

Pengalaman pada pekerjaan ini menunjukkan bahwa sebagian besar kegagalan dapat dicegah dengan memeriksa sebelum pemrosesan dimulai. Bagian ini mengumpulkan langkah-langkah itu menjadi satu daftar periksa yang dapat dijalankan pada setiap berkas sebelum ia masuk ke alur.

Pertama, periksa bentuk dan tipe data. Setiap berkas citra harus memiliki dimensi yang sesuai dengan grid yang diharapkan, yaitu 1.671×2.561 piksel pada resolusi 30 meter untuk area kajian ini. Bila dimensinya berbeda, berkas itu tidak akan sejajar dengan berkas lain; kesalahan itu akan menyebar ke seluruh analisis berikutnya. Selain itu, tipe data harus diketahui: apakah nilainya bilangan bulat atau pecahan, serta apakah skala penyimpanannya 0–1, 0–10.000, atau kelas diskret.

Kedua, periksa nilai kosong. `isfinite` dijalankan pada setiap larik sebelum dipakai, lalu jumlah nilai kosongnya dilaporkan. Nilai kosong pada larik masukan solver adalah penyebab kegagalan menyeluruh yang dibahas pada tahap 6; pemeriksaan itu murah. Nilai kosong tidak boleh dibiarkan; ia harus diisi dengan metode yang jelas, atau pikselnya dikeluarkan dari analisis.

Ketiga, periksa rentang nilai. Nilai reflektansi yang sah berada pada rentang 0 sampai 1, atau 0 sampai 10.000 sebelum dibagi. Bila rentangnya jauh di luar itu, berarti skala berkas berbeda dari yang

diasumsikan. Kasus kanal SCL yang ikut terbagi sepuluh ribu adalah contoh pemeriksaan rentang yang terlewat: kelas diskret 0–11 berubah menjadi pecahan kecil; masking awan gagal tanpa peringatan.

Keempat, periksa kesesuaian kanal. Untuk endmember, jumlah nilai harus sama dengan jumlah kanal sensor yang dipakai. Untuk citra, kanal yang akan dipakai harus benar-benar ada, dan panjang gelombangnya harus benar. Bila satu kanal red-edge hilang atau tertukar, pemisahan varietas akan melemah tanpa penjelasan yang jelas.

Kelima, periksa kesesuaian tanggal. Jendela tanggal citra harus dibandingkan dengan tanggal pembungaan median yang dihitung dari MODIS. Pada pekerjaan ini, perbandingan itulah yang mengungkap bahwa komposit lama mulai 39 hari setelah pembungaan median. Perbandingan itu hanya memerlukan satu angka dari tahap 4, serta satu tanggal dari metadata citra, tetapi kegagalan yang dicegahnya sangat besar.

Daftar periksa ini bukan pengganti pemahaman, tetapi ia menutup kelas kegagalan yang paling sering terjadi. Sebagian besar langkah di dalamnya memerlukan waktu kurang dari satu detik, sedangkan kegagalan yang dicegahnya dapat menghabiskan sehari-hari kerja. Itulah perwujudan paling konkret dari prinsip yang dinyatakan di awal bab: periksa sebelum memproses, dan periksa yang murah sebelum yang mahal.

BAB X HASIL: APA YANG BISA DAN TIDAK BISA DIPETAKAN

10.1 Dua pertanyaan yang harus dijawab terpisah

Bab ini melaporkan hasil. Ada dua pertanyaan yang perlu dijawab, dan keduanya harus dijawab secara terpisah karena jawabannya berbeda.

Pertanyaan pertama bersifat teknis: seberapa baik algoritme dapat memisahkan kelima varietas (variety), bila diberi data yang bersih dan terkendali? Pertanyaan ini dijawab oleh pengujian pada piksel sintetis, dan jawabannya memberi batas atas kemampuan.

Pertanyaan kedua bersifat praktis: seberapa baik pemisahan itu bekerja pada citra nyata, dengan segala derau (noise) dan ketidakpastiannya? Pertanyaan ini dijawab oleh pengujian pada citra, dan jawabannya selalu lebih rendah daripada yang pertama.

Memisahkan kedua pertanyaan itu penting, karena bila digabung, penyebab suatu kegagalan menjadi kabur: apakah algoritmenya yang kurang baik, atau datanya yang tidak memadai?

Ada alasan kedua yang lebih mendasar, dan alasan itu menyangkut cara membaca angka. Akurasi pemisahan spektral mengukur seberapa baik sebuah mesin membedakan bentuk spektrum yang telah diringkas menjadi sembilan bilangan. Ia tidak berbicara tentang sawah, tentang petani, atau tentang varietas yang benar-benar tumbuh di suatu petak. Akurasi pemetaan tematik, sebaliknya, mengukur seberapa sering peta yang dihasilkan benar-benar cocok dengan keadaan di lapangan. Angka pertama adalah properti dari spektrum dan algoritme; angka kedua adalah properti dari produk akhir. Bab ini melaporkan keduanya sejauh yang dapat diukur, dan menyatakan dengan terus terang bahwa yang kedua belum tersedia.

Cara membaca bab ini karena itu adalah sebagai berikut. Bagian 9.2 dan 9.3 melaporkan apa yang diukur: kemampuan mesin dan hasil pada citra nyata. Bagian 9.4 sampai 9.6 membahas apa arti angka-angka itu, termasuk mengapa satu varietas selalu muncul di puncak dan mengapa polanya bukan derau. Bagian 9.7 menyatakan batasnya, dan bagian 9.8 menutup dengan ringkasan.

10.2 Kemampuan mesin: akurasi pemisahan spektral

Pengujian pertama membangkitkan piksel sintetis dari setiap spektrum endmember (endmember), menambahkan derau pada tingkat yang realistis untuk reflektansi (reflectance) permukaan Sentinel-2, lalu menjalankan penguraian dan memeriksa apakah setiap piksel dikenali kembali sebagai varietas asalnya.

Hasil pada derau 0,010 — tingkat yang mencerminkan citra nyata — adalah sebagai berikut.

Varietas	Derau 0,005	Derau 0,010	Penilaian
Ciherang	100,0%	100,0%	Dapat dipetakan
IR64	85,3%	59,7%	Tidak dapat dipisahkan
Inpari32	99,9%	96,1%	Dapat dipetakan
Inpari32_WBC	100,0%	100,0%	Dapat dipetakan
Mekongga	100,0%	100,0%	Dapat dipetakan
Total	97,0%	91,1%	

Kesimpulan utamanya: **empat dari lima varietas dapat dipetakan** dengan akurasi 96 sampai 100 persen. Satu varietas, **IR64**, tidak dapat dipisahkan secara andal.

Rincian kesalahan IR64 memperlihatkan polanya: dari seluruh piksel yang sebenarnya IR64, sebanyak **28,9 persen dikenali sebagai Ciherang** dan 11,4 persen dikenali sebagai Inpari32. Penyebabnya langsung terlihat dari jarak spektral (spectral distance): pasangan Ciherang–IR64 berjarak 0,1222 — terpendek di antara seluruh pasangan varietas.

Yang perlu ditegaskan: ini **bukan kegagalan algoritme**. Pengujian pada derau nol memberi akurasi 100 persen dengan galat 0,0000, yang membuktikan implementasinya benar. Ini juga bukan kegagalan endmember, sebagaimana akan dibuktikan pada Bab 11 melalui perbandingan bentuk spektrum. Ini adalah **batas informasi**: perbedaan antara Ciherang dan IR64 pada sembilan kanal (band) Sentinel-2 memang lebih kecil daripada derau citra.

Ada satu nuansa yang menarik dan berguna secara praktis. Bila hanya Ciherang dan IR64 yang diuji secara berpasangan — tanpa tiga varietas lain bersaing — akurasi IR64 naik menjadi sekitar 91 persen. Artinya IR64

bukan mustahil dipisahkan; ia kalah bersaing ketika empat kelas lain turut berada dalam ruang solusi. Untuk kajian yang secara khusus membandingkan Ciherang dan IR64, pemisahan berpasangan akan memberi hasil yang jauh lebih baik.

Mengapa akurasi berpasangan jauh lebih tinggi

Selisih antara 91 persen (berpasangan) dan 59,7 persen (lima kelas) adalah selisih yang terlalu besar untuk diabaikan, dan sebabnya perlu dijelaskan karena ia menyentuh inti cara kerja penguraian spektral (spectral unmixing).

Pada dasarnya FCLS mencari kombinasi fraksi (fraction) yang jumlahnya satu dan tidak negatif, sehingga campuran lima endmember menghasilkan kembali spektrum piksel. Ketika hanya dua endmember yang tersedia, ruang solusi menyusut menjadi satu garis lurus di dalam ruang sembilan dimensi: solusinya adalah satu titik pada segmen antara kedua spektrum itu. Pada ruang sesempit itu, algoritme tidak punya banyak pilihan. Bila spektrum yang diuraikan memang berasal dari salah satu ujung segmen, satu-satunya cara agar jumlah fraksi tetap satu adalah menempatkan fraksi itu pada ujung yang benar. Tidak ada kelas ketiga yang bisa menyerap sisa fraksi.

Keadaan berubah secara mendasar ketika lima endmember tersedia. Sekarang ruang solusi adalah simpleks (simplex) berdimensi empat di dalam ruang sembilan dimensi — jauh lebih luas. Sebuah piksel IR64 yang mengandung sedikit derau dapat dijelaskan dengan baik oleh campuran sebagian Ciherang, sebagian Inpari32, dan sebagian kecil varietas lain. Secara matematis campuran itu sah, dan galat rekonstruksinya rendah. Tetapi interpretasinya salah: piksel itu sebenarnya satu varietas, namun diuraikan menjadi campuran beberapa varietas.

Di sinilah pentingnya jarak spektral. Bila jarak Ciherang–IR64 (0,1222) lebih kecil daripada derau citra pada arah yang memisahkan keduanya, maka tidak ada cukup informasi untuk menentukan ke ujung mana sebuah piksel harus ditempatkan. Sebagian piksel akan jatuh ke sisi yang salah. Menambah tiga varietas lain tidak menciptakan informasi baru tentang arah Ciherang–IR64; ia justru menambah derajat kebebasan yang membuat kesalahan penempatan lebih mudah terjadi. Itulah sebabnya akurasi lima kelas (59,7 persen) lebih rendah daripada akurasi berpasangan (91 persen), meskipun datanya sama persis.

Kesimpulan praktisnya jelas dan berulang kali berguna: **jumlah kelas yang dipaksa diuraikan sekaligus menentukan akurasi setiap kelas.** Memetakan lima varietas dalam satu lintasan penguraian menuntut pemisahan yang jauh lebih halus daripada memetakan dua varietas. Bila kepentingan kajian hanya pada satu pasangan varietas, menambahkan varietas lain ke dalam model bukan tindakan netral — ia menurunkan akurasi pasangan yang sebenarnya ingin dipetakan.

Derau adalah penentu, bukan kode

Tabel di atas memperlihatkan pola yang konsisten: pada derau 0,005, akurasi total adalah 97,0 persen; pada derau 0,010, akurasi turun menjadi 91,1 persen. Penurunan terbesar terjadi pada IR64, yang jatuh dari 85,3 persen menjadi 59,7 persen, sedangkan empat varietas lain hampir tidak terpengaruh. Perilaku ini bukan kebetulan. Ia memperlihatkan bahwa yang membatasi akurasi adalah seberapa besar derau dibandingkan jarak antar-kelas. Varietas yang jaraknya jauh dari semua kelas lain tetap aman meskipun derau naik; varietas yang jaraknya tipis dari tetangganya langsung jatuh ketika derau naik sedikit.

Karena itu pengujian pada derau nol memiliki nilai diagnostik yang besar, meskipun ia tidak realistis. Akurasi 100 persen dengan galat 0,0000 pada derau nol memisahkan dua kemungkinan yang sering tercampur: kesalahan implementasi dan keterbatasan data. Bila akurasi pada derau nol pun tidak mencapai 100 persen, berarti ada cacat pada kode — misalnya matriks endmember yang salah susun, atau kendala yang tidak diterapkan dengan benar. Karena pada derau nol hasilnya sempurna, dapat dipastikan bahwa seluruh penurunan akurasi pada derau 0,010 berasal dari data, bukan dari program. Pengujian murah ini sebaiknya dijadikan pemeriksaan rutin setiap kali implementasi diubah.

Akurasi pada campuran acak

Pengujian tambahan pada campuran acak lima kelas memberi akurasi 62,4 persen pada derau 0,010. Angka ini lebih rendah daripada pengujian piksel murni (pure pixel), dan itu wajar: semakin tercampur sebuah piksel, semakin sulit diuraikan. Implikasi praktisnya penting — **akurasi pemetaan bergantung pada seberapa tercampur piksel di lapangan.** Pada sawah dengan petak besar dan seragam, akurasinya mendekati angka piksel murni. Pada sawah dengan petak kecil dan bercampur, akurasinya lebih dekat ke angka campuran.

Kedua angka itu — 91,1 persen dan 62,4 persen — sebaiknya dipandang bukan sebagai dua hasil yang bertentangan, melainkan sebagai dua ujung satu rentang. Ujung atas terjadi bila setiap piksel hanya memuat satu varietas; ujung bawah terjadi bila setiap piksel memuat campuran acak dari kelima varietas dengan proporsi yang bervariasi bebas. Kenyataan di lapangan selalu berada di antara keduanya. Semakin besar dan seragam petak sawah dibandingkan ukuran piksel, semakin dekat hasilnya ke ujung atas; semakin kecil dan bercampur petak itu, semakin dekat ke ujung bawah.

Dari sudut pandang perencanaan, hal ini berarti **akurasi bukan satu angka tunggal yang melekat pada metode, melainkan angka yang bergantung pada lanskap tempat metode itu dipakai**. Angka 91,1 persen yang dilaporkan di sini berlaku untuk kondisi piksel murni, dan karena itu bersifat optimistis. Angka 62,4 persen berlaku untuk kondisi pencampuran penuh, dan bersifat pesimistis. Nilai sebenarnya untuk area kajian tertentu berada di antaranya, dan hanya pengukuran lapangan yang dapat menentukannya secara pasti.

Arti praktis untuk memilih lokasi kajian

Uraian di atas membawa konsekuensi langsung bagi keputusan yang jauh lebih awal daripada pemrosesan: **pemilihan lokasi kajian**. Sebuah area yang tersusun dari petak-petak sawah besar, seragam, dan ditanami satu varietas per petak akan jauh lebih ramah terhadap penguraian daripada area yang tersusun dari petak-petak kecil yang saling berselang-seling.


Pada petak besar, mayoritas piksel berada di bagian dalam petak, jauh dari batas. Piksel seperti itu menerima pantulan dari satu jenis tanaman saja, sehingga fraksinya mendekati murni. Pada petak kecil, proporsi piksel tepi meningkat tajam. Bila petak hanya berukuran beberapa piksel, hampir seluruh pikselnya adalah piksel tepi — piksel yang memuat campuran tanaman dari dua atau lebih petak, ditambah pematang, saluran air, dan tanah. Untuk piksel seperti itu, tidak ada jawaban tunggal yang benar, karena piksel itu memang bukan satu varietas. Penguraian akan memaksakan jawaban, dan jawaban itu akan salah tidak peduli seberapa baik algoritmenya.

Karena itu pemilihan lokasi sebaiknya memperhitungkan ukuran petak rata-rata sebelum pengunduhan citra dilakukan. Idealnya area kajian didominasi petak yang lebarnya beberapa kali ukuran piksel, sehingga

bagian dalam petak cukup luas untuk memberi piksel murni dalam jumlah yang berarti. Selain itu, memilih area dengan keragaman varietas yang lebih rendah akan membantu: memetakan dua atau tiga varietas yang jaraknya berjauhan memberi hasil yang jauh lebih andal daripada memetakan lima varietas yang sebagian berdekatan secara spektral. Dengan kata lain, akurasi yang tinggi tidak hanya diperoleh dengan metode yang baik, tetapi juga dengan memilih pertanyaan yang sesuai dengan kemampuan datanya.

10.3 Hasil pada citra nyata

Pengujian kedua menjalankan penguraian pada 1.994.687 piksel padi pada citra Sentinel-2. Dua komposit (composite) dibandingkan: komposit jendela lama (Mei–Agustus 2026) dan komposit jendela pembungaan (24 Februari – 3 Mei 2026).



Gambar 10.1. Varietas padi dominan pada setiap piksel. Panel (a) seluruh area kajian; panel (b) perbesaran 21 x 21 km pada blok terpadat. Abu-abu = non-padi atau tertutup awan.

Varietas	Jendela lama	Jendela pembungaan	Selisih
Ciherang	0,0849	0,0711	-16,3%
IR64	0,0777	0,0468	-39,8%
Inpari32	0,1620	0,0879	-45,8%
Inpari32_WBC	0,2461	0,2396	-2,6%
Mekongga	0,4293	0,5546	+29,2%

Perubahan paling mencolok adalah pada Mekongga, yang fraksinya naik dari 0,4293 menjadi 0,5546, dan pada Inpari32 yang turun hampir separuh.

Namun ada satu penanda yang harus diperhatikan, dan penanda itu mencegah kesimpulan yang terlalu cepat. **Persentase piksel ekstrem (extreme pixel) naik** dari 0,004 persen pada jendela lama menjadi **3,815 persen** pada jendela pembungaan. Piksel ekstrem adalah piksel yang seluruh fraksinya mendekati nol atau mendekati satu — tanda solusi terdorong ke batas, yang berarti endmember tidak mencakup piksel itu.

Kenaikan penanda itu menunjukkan bahwa hasil pada jendela pembungaan **belum tentu lebih baik**, meskipun fraksinya berbeda. Bab 11 menjelaskan mengapa.

Membaca pergeseran fraksi dengan benar

Tabel di atas mudah disalahbaca sebagai bukti bahwa jendela pembungaan menghasilkan peta yang lebih benar. Pembacaan seperti itu tidak dapat dipertahankan, dan alasannya terletak pada penanda yang menyertainya.

Pertama, perlu diperhatikan bahwa yang berubah ketika jendela tanggal digeser bukan hanya fraksi masing-masing varietas, tetapi juga kepercayaan solusinya. Pada jendela lama, hanya 0,004 persen piksel yang tergolong ekstrem — jumlah yang sangat kecil. Pada jendela pembungaan, angka itu melonjak menjadi 3,815 persen, hampir seribu kali lipat. Piksel ekstrem adalah piksel yang solusinya menempel pada dinding simpleks: seluruh fraksinya nol, atau seluruhnya terkumpul pada satu varietas. Piksel seperti itu menandakan bahwa spektrum yang diuraikan berada di luar wilayah yang dapat dijelaskan oleh kumpulan endmember. Ketika jumlah piksel semacam itu meningkat pesat, yang meningkat bukan kualitas hasil, melainkan jumlah piksel yang tidak terjelaskan oleh model.

Kedua, arah pergeseran fraksi dapat dijelaskan tanpa mengandaikan bahwa jendela baru lebih benar. Pada jendela pembungaan, sawah berada pada fase puncak pertumbuhan, dengan biomassa tinggi dan tutupan kanopi (canopy) rapat. Sebagaimana dibahas pada Bab 11, endmember SpecLib diukur pada kanopi dan karena itu memiliki nilai NIR yang jauh lebih tinggi daripada piksel citra, yang selalu memuat tanah, air, dan pematang. Ketika komposit jendela pembungaan menangkap puncak kanopi, spektrum piksel


bergerak mendekati endmember pada beberapa kanal, sehingga solusinya lebih sering menempel pada satu kelas — dalam hal ini Mekongga, yang bentuk spektrumnya paling sesuai. Kenaikan fraksi Mekongga dari 0,4293 menjadi 0,5546 karena itu konsisten dengan peningkatan jumlah piksel ekstrem, dan keduanya berasal dari sebab yang sama: solusi terdorong lebih keras ke batas.

Ketiga, penurunan fraksi Inpari32 sebesar 45,8 persen dan IR64 sebesar 39,8 persen tidak boleh ditafsirkan sebagai bukti bahwa kedua varietas itu lebih sedikit ditanam pada jendela baru. Jendela lama dan jendela baru menangkap sawah pada fase yang berbeda, dan perbedaan fase mengubah spektrum lebih besar daripada perbedaan varietas. Karena itu perbandingan kedua kolom tabel di atas adalah perbandingan dua fase, bukan perbandingan dua komposisi tanam. Menarik kesimpulan tentang luas tanam dari perbandingan semacam itu akan keliru.


Kesimpulan yang dapat diambil dari bagian ini adalah bahwa perbaikan jendela tanggal menghasilkan fraksi yang berbeda, tetapi belum terbukti menghasilkan fraksi yang lebih benar. Yang mencegah kesimpulan yang terlalu cepat justru adalah penanda piksel ekstrem. Bila penanda itu diabaikan, hasil pada jendela pembungaan akan tampak seperti kemajuan yang jelas, padahal ia membawa serta masalah kepercayaan solusi yang lebih besar. Inilah pelajaran metodologis yang diulang berkali-kali dalam buku ini: satu angka tunggal hampir selalu menyesatkan, dan keputusan harus diambil dari beberapa penanda sekaligus.

10.4 Dominasi Mekongga dan mengapa ia bukan artefak

Seluruh percobaan pada pekerjaan ini menghasilkan kesimpulan yang sama: **Mekongga dominan**. Hal itu terjadi pada 15 kombinasi setelan reduksi dan pemetaan kanal, pada tiga sensor yang diuji, pada dua masker (mask) padi yang berbeda, pada dua jendela tanggal, dan pada empat skema endmember. Fraksi Mekongga berkisar antara 0,26 dan 0,55 tergantung perlakuan, tetapi ia selalu menempati peringkat pertama atau kedua.



Gambar 10.2. Fraksi rata-rata per varietas pada seluruh piksel padi.



Gambar 10.3. Fraksi varietas Mekongga per piksel padi, disajikan sebagai bidang kontinu. Warna gelap menandakan fraksi rendah, kuning terang menandakan fraksi tinggi; putih = non-padi atau tertutup awan.

Konsistensi seperti itu menuntut penjelasan. Ada dua kemungkinan: entah Mekongga memang varietas yang paling luas ditanam di area kajian, atau ada sebab sistematis yang membuatnya selalu dominan.

Beberapa bukti mendukung kemungkinan pertama. **Akurasi pemisahan Mekongga adalah 100 persen** pada pengujian matriks kekeliruan (confusion matrix) — artinya bila sebuah piksel memang Mekongga, algoritme selalu mengenalinya dengan benar. Selain itu, dominasi itu bertahan meskipun endmember diskalakan, meskipun kelas non-padi ditambahkan, dan meskipun koreksi per kanal diterapkan.

Satu pengujian memberi bukti tambahan yang penting. Ketika penskalaan endmember diterapkan pada berbagai faktor, **fraksinya tidak berubah sama sekali** — identik sampai empat angka desimal. Hal ini konsisten dengan sifat invarian skala (scale invariance) yang dibahas pada Bab 3, dan artinya dominasi Mekongga bukan akibat skala endmember.

Kesimpulan yang dapat ditarik: **dominasi Mekongga adalah geometri spektral yang nyata**. Ia bukan artefak penskalaan, bukan artefak masker, bukan artefak jendela tanggal. Ia mencerminkan bahwa spektrum Mekongga adalah yang paling sesuai dengan piksel padi pada citra.

Apakah itu berarti Mekongga benar-benar varietas yang paling luas? **Belum dapat dipastikan**. Yang dapat dikatakan adalah bahwa secara spektral, piksel-piksel padi di area itu paling mirip dengan Mekongga. Verifikasi (verification) memerlukan data lapangan.

Seluruh bukti pendukung, ditimbang satu per satu

Karena dominasi Mekongga adalah temuan yang paling menonjol sekaligus paling mudah disalahpahami, seluruh bukti yang mendukungnya perlu ditimbang secara terbuka.

Bukti pertama adalah akurasi pemisahan Mekongga yang mencapai 100 persen, bahkan pada derau 0,010. Angka ini menunjukkan bahwa bila algoritme diberi piksel yang memang berasal dari spektrum Mekongga, ia tidak pernah salah mengenalinya. Penting untuk dipahami bahwa ini adalah properti yang jarang: hanya Ciherang, Inpari32_WBC, dan Mekongga yang mencapai 100 persen pada derau realistis, sedangkan IR64 jatuh sampai 59,7 persen. Jadi Mekongga bukan hanya dominan dalam fraksi, tetapi juga paling andal dikenali.

Bukti kedua adalah ketahanan (robustness) dominasi terhadap berbagai perlakuan. Pada 15 kombinasi setelan reduksi dan pemetaan kanal, Mekongga tetap di peringkat pertama atau kedua. Ia tetap dominan ketika endmember diskalakan dengan faktor berbeda, ketika kelas air dan tanah ditambahkan ke dalam penguraian, dan ketika koreksi per kanal diterapkan. Yang lebih kuat lagi, dominasi itu bertahan ketika masker padi diganti dengan masker yang berbeda, dan ketika jendela tanggal digeser dari Mei–Agustus ke Februari–Mei. Perubahan-perubahan ini menyentuh hampir setiap bagian dari rantai pemrosesan, dan Mekongga tetap muncul

di puncak. Bila dominasi itu berasal dari satu kesalahan tertentu, setidaknya satu perlakuan seharusnya menghilangkannya.

Bukti ketiga adalah invarian fraksi terhadap penskalaan. Sebagaimana dijelaskan pada Bab 3, FCLS dengan kendala jumlah-satu bersifat invarian terhadap penskalaan seragam dari seluruh endmember: mengalikan semua spektrum endmember dengan konstanta yang sama tidak mengubah solusi fraksinya, karena campuran tetap dijelaskan oleh kombinasi yang sama. Ketika diuji secara empiris, fraksi Mekongga tidak berubah sama sekali hingga empat angka desimal di seluruh faktor skala yang dicoba. Fakta ini menyingkirkan satu penjelasan yang tampak masuk akal sejak awal — bahwa Mekongga dominan karena spektrumnya kebetulan berskala lebih besar daripada yang lain.

Bukti keempat datang dari pengujian ekstraksi piksel murni. Ketika endmember diturunkan langsung dari citra dengan PPI, tanpa memakai Speclib sama sekali, salah satu endmember hasil ekstraksi tetap paling cocok dengan Mekongga, dengan sudut spektral hanya 2,8 derajat dan korelasi bentuk 0,9988 — kecocokan terbaik di antara seluruh endmember yang diekstraksi. Artinya, spektrum yang benar-benar ada di citra dan paling murni menyerupai Mekongga, meskipun endmember Speclib tidak dilibatkan dalam proses ekstraksi itu. Ini adalah bukti yang berasal dari data, bukan dari pustaka spektral.

Bukti kelima, dan yang paling halus, adalah koreksi per kanal. Perlakuan ini mengubah urutan dominasi: ketika koreksi per kanal diterapkan, Inpari32 naik ke peringkat pertama dengan fraksi 0,3416 dan Mekongga turun ke 0,2603. Pada pandangan pertama, ini tampak seperti bukti bahwa dominasi Mekongga memang artefak. Namun perlakuan itu sendiri telah terbukti merusak: koreksi per kanal menurunkan akurasi dari 91,1 persen menjadi 81,6 persen dan menyusutkan jarak antar-kelas 45 sampai 60 persen. Jadi perlakuan yang membalik urutan dominasi adalah perlakuan yang sudah terbukti salah. Kenyataan bahwa dominasi Mekongga runtuh justru ketika metodenya dirusak memperkuat, bukan melemahkan, kesimpulan bahwa pada metode yang benar Mekongga memang dominan.

Ditimbang bersama, kelima bukti ini menunjuk ke satu arah: dominasi Mekongga adalah sifat spektral yang nyata dari data, bukan efek samping dari pilihan pemrosesan. Yang belum dapat ditetapkan adalah

apakah kemiripan spektral itu mencerminkan luas tanam yang sesungguhnya. Spektrum dapat menyerupai suatu endmember karena varietas itu memang banyak ditanam, tetapi dapat juga karena varietas lain pada kondisi tertentu menghasilkan spektrum yang berdekatan. Pemisahan kedua kemungkinan itu memerlukan koordinat petak dan varietas yang diketahui dari lapangan — persis data yang belum tersedia.

10.5 Pola spasial: membedakan struktur nyata dari derau

Hasil penguraian menghasilkan peta. Tetapi peta yang tampak berpola belum tentu mengandung informasi — bisa saja ia hanya sebaran acak yang kebetulan tampak teratur.

Untuk menguji hal ini, dua ukuran dipakai. **Pertama**, simpangan baku rata-rata blok 32×32 piksel dibandingkan dengan simpangan baku yang diharapkan bila nilai piksel tersebar acak. **Kedua**, korelasi antara piksel yang bertetangga dibandingkan dengan korelasi pada pembanding acak.

Ukuran	Nilai
Simpangan baku rata-rata blok 32×32 piksel	0,1644
Simpangan baku bila nilai tersebar acak	0,0060
Rasio	27,2×
Korelasi piksel bertetangga	0,714
Korelasi pembanding acak	-0,0005

Hasilnya tegas. Keragaman antar blok mencapai **27 kali** nilai yang diharapkan bila piksel tersebar acak, dan piksel bertetangga memiliki korelasi 0,714 dibandingkan hampir nol pada pembanding acak.

Artinya piksel-piksel dengan fraksi serupa **mengelompok secara geografis**, sebagaimana layaknya hamparan sawah yang ditanami varietas sama. Bila fraksinya berasal dari derau, pola seperti itu tidak akan terbentuk.


Uji ini penting karena membedakan dua kemungkinan yang tampak sama pada peta: hasil pemodelan yang benar-benar menangkap pola tanam, atau sebaran acak yang kebetulan tampak berpola. Dengan rasio 27 kali, kemungkinan kedua dapat disingkirkan.

Kedua ukuran itu saling melengkapi, dan keduanya perlu karena masing-masing menutup celah yang ditinggalkan yang lain. Simpangan baku antar blok mengukur keragaman pada skala besar: apakah satu bagian peta berbeda dari bagian lain. Korelasi antar piksel bertetangga mengukur kesinambungan pada skala kecil: apakah nilai berubah secara berangsur dari piksel ke piksel, atau melompat-lompat. Derau yang murni acak akan memberi nilai rendah pada kedua ukuran sekaligus: tidak ada perbedaan sistematis antar wilayah, dan tidak ada kesinambungan antar piksel. Yang ditemukan justru sebaliknya pada kedua ukuran, dengan selisih yang sangat besar.

Perlu ditegaskan pula apa yang **tidak** dibuktikan oleh uji ini. Uji struktur spasial menunjukkan bahwa peta mengandung pola yang nyata, bukan derau. Ia tidak menunjukkan bahwa pola itu adalah pola varietas yang benar. Sebuah peta dapat berpola sangat kuat dan tetap salah secara tematik — misalnya bila seluruh area bergeser secara sistematis karena endmember tidak sesuai dengan skala citra. Yang disingkirkan oleh uji ini adalah satu penjelasan alternatif yang spesifik, yaitu bahwa fraksi berasal dari derau. Ia tidak menggantikan validasi (validation) lapangan.

10.6 Sebaran padi dan apa yang dikatakannya

Sebaran piksel padi pada area kajian tidak merata, dan polanya bermakna.



Gambar 10.4. Sebaran piksel padi. Panel (a) seluruh area kajian; panel (b) perbesaran 21 x 21 km pada blok terpadat, ditandai kotak merah pada panel (a). Hijau = padi, putih = non-padi atau tertutup awan.

Kuadran	Padi (% dari piksel sah)
Barat Daya	87,0%

Kuadran	Padi (% dari piksel sah)
Tenggara	42,1%
Barat Laut	41,0%
Timur Laut	16,5%

Perbedaan antara kuadran (quadrant) barat daya (87,0 persen) dan timur laut (16,5 persen) mencapai lebih dari lima kali. Pola ini masuk akal secara geografis: kuadran barat daya bertepatan dengan dataran aluvial yang luas dan terjangkau irigasi teknis, sedangkan kuadran timur laut bertepatan dengan wilayah yang lebih berbukit dan berperkebunan.

Kesesuaian antara pola yang ditemukan dan keadaan geografis yang diketahui merupakan bentuk validasi tidak langsung: bila hasilnya acak, tidak akan ada kesesuaian seperti itu.

Nilai validasi tidak langsung ini perlu ditempatkan secara tepat. Ia tidak sama dengan validasi lapangan, karena ia membandingkan hasil dengan pengetahuan umum tentang wilayah, bukan dengan pengukuran varietas pada petak tertentu. Namun ia memiliki kekuatan yang tidak dimiliki pengujian statistik: pengujian statistik hanya dapat menyatakan bahwa pola itu tidak acak, sedangkan kesesuaian geografis menyatakan bahwa pola itu tidak acak **dengan cara yang sesuai dengan kenyataan**. Sebuah kesalahan pemrosesan yang sistematis, misalnya pergeseran koordinat, akan menghasilkan pola yang tidak acak tetapi tidak akan cocok dengan batas-batas geografis yang diketahui. Karena pola yang ditemukan cocok, sekelompok kesalahan sistematis semacam itu dapat disingkirkan.

Kesesuaian ini juga memiliki implikasi praktis untuk pemilihan lokasi pengambilan sampel lapangan. Karena padi terkonsentrasi di kuadran barat daya, survei lapangan yang efisien sebaiknya memusatkan petak contoh di sana, dengan beberapa petak tambahan di kuadran lain sebagai pembanding. Pengambilan sampel yang tersebar merata di seluruh area akan membuang banyak tenaga pada wilayah yang sebagian besar bukan sawah.

10.7 Apa yang tidak dapat dipetakan

Bagian ini perlu disampaikan dengan terus terang, karena batas kemampuan adalah bagian dari hasil.

IR64 tidak dapat dipisahkan dari Ciherang. Akurasi 59,7 persen, dengan 28,9 persen piksel IR64 dikenali sebagai Ciherang. Jarak spektral keduanya 0,1222, terpendek dari seluruh pasangan. Pemisahan keduanya memerlukan sensor dengan lebih banyak kanal, bukan penyesuaian pemrosesan.

Pemetaan varietas dengan Landsat tidak mungkin. Jarak antar-varietas pada empat kanal Landsat menyusut menjadi sekitar separuh, dengan pasangan Ciherang–IR64 hanya berjarak 0,0610. Selain itu Landsat tidak memiliki kanal red-edge sama sekali.

Fraksi absolut belum tervalidasi lapangan. Seluruh angka akurasi pada bab ini adalah akurasi **pemisahan spektral** — seberapa baik algoritme membedakan spektrum. Yang belum diukur adalah akurasi **pemetaan tematik** — seberapa sering peta yang dihasilkan benar-benar sesuai dengan varietas yang ditanam di lapangan. Kedua hal itu berbeda, dan yang kedua memerlukan data lapangan.

Apa yang harus diukur di lapangan

Karena validasi lapangan adalah satu-satunya cara mengubah angka pada bab ini dari pernyataan tentang spektrum menjadi pernyataan tentang peta, perlu dinyatakan secara konkret apa yang harus diukur agar hasil ini dapat disebut tervalidasi.

Yang paling pokok adalah **koordinat petak contoh beserta varietas yang ditanam di dalamnya**. Setiap petak contoh harus memiliki posisi yang tercatat dengan ketelitian yang memadai — mengingat ukuran piksel 30 meter, ketelitian beberapa meter sudah memadai — serta identitas varietas yang dikonfirmasi, bukan diduga dari catatan penyuluh atau dari kebiasaan setempat. Varietas harus dipastikan dari sumber yang dapat dipercaya, misalnya benih yang dipakai petani pada musim (season) tanam (cropping season) yang bersangkutan. Jumlah petak contoh perlu memadai untuk memberi taksiran akurasi yang berarti; sebagai patokan awal, minimal tiga puluh petak yang tersebar, mencakup kelima varietas sejauh mungkin.

Yang tidak kalah penting adalah **kesesuaian waktu**. Petak contoh harus diamati pada musim tanam yang sama dengan citra yang dianalisis, dan sebaiknya pada fase yang serupa. Bila varietas dikonfirmasi pada musim yang berbeda dari musim citra, maka yang dibandingkan bukan lagi

varietas pada citra itu, melainkan varietas pada musim lain. Mengingat betapa besar pengaruh fase terhadap spektrum — sebagaimana ditunjukkan oleh lonjakan piksel ekstrem ketika jendela tanggal digeser — kesesuaian waktu bukan hal yang dapat dikompromikan.

Selain identitas varietas, beberapa pengukuran tambahan sangat berguna. **Luas dan bentuk petak** perlu dicatat, karena keduanya menentukan seberapa besar proporsi piksel tepi dan karena itu menentukan ke arah mana akurasi sebenarnya cenderung bergerak antara 91,1 persen dan 62,4 persen. **Kondisi tanaman pada saat pengamatan**, misalnya tinggi tanaman dan tingkat penutupan kanopi, perlu dicatat karena kondisi itu mempengaruhi seberapa jauh spektrum petak menyimpang dari endmember. **Tanggal tanam dan tanggal pembungaan** petak contoh perlu dicatat karena keduanya memungkinkan perbandingan langsung dengan fenologi (phenology) yang diturunkan dari MODIS. Dan bila memungkinkan, **pengukuran spektrum lapangan** pada beberapa petak akan sangat berharga, karena ia memberi jembatan antara endmember SpecLib dan spektrum yang benar-benar terlihat satelit pada petak tertentu.

Dengan data itu, akurasi tematik dapat dihitung dengan matriks kekeliruan antara varietas lapangan dan varietas hasil penguraian, dan angka yang diperoleh dapat dibandingkan langsung dengan angka pemisahan spektral pada bab ini. Baru pada titik itu klaim tentang pemetaan varietas dapat dinyatakan tervalidasi. Selama data itu belum tersedia, seluruh angka pada bab ini harus dibaca sebagai pernyataan tentang kemampuan membedakan spektrum — sebuah pernyataan yang sah dan berguna, tetapi bukan pernyataan tentang kebenaran peta.

10.8 Ringkasan

Pertanyaan	Jawaban
Berapa varietas yang dapat dipetakan?	4 dari 5
Akurasi pemisahan pada derau realistis	91,1%
Varietas yang tidak dapat dipisahkan	IR64 (59,7%; jarak 0,1222 dari Ciherang)
Akurasi pada campuran acak	62,4%
Varietas dominan	Mekongga (fraksi 0,43–0,55, akurasi 100%)
Apakah pola peta bermakna?	Ya — keragaman 27× acak, korelasi tetangga 0,714

Pertanyaan	Jawaban
Apakah fraksi absolut tervalidasi?	Belum — memerlukan data lapangan

Dua kesimpulan yang saling melengkapi dapat ditarik dari bab ini. Pertama, pemetaan varietas padi dengan Sentinel-2 **layak dilaksanakan** untuk empat varietas, dan hasilnya mengandung struktur yang nyata, bukan derau. Kedua, hasil itu **belum tervalidasi secara tematik**, sehingga penggunaannya untuk pengambilan keputusan operasional harus disertai kesadaran akan keterbatasan itu.

Antara kedua kesimpulan itu terletak seluruh isi bab ini. Akurasi pemisahan yang tinggi menunjukkan bahwa perbedaan antar-varietas memang terekam dalam sembilan kanal Sentinel-2, dan bahwa penguraian dapat memanfaatkannya. Kegagalan IR64 menunjukkan bahwa kemampuan itu terbatas pada varietas yang jaraknya cukup lebar, dan bahwa keterbatasan itu bersifat fisik, bukan sekadar teknis. Akurasi campuran acak yang lebih rendah menunjukkan bahwa hasil di lapangan bergantung pada seberapa besar piksel tercampur, sehingga pemilihan lokasi menjadi keputusan yang menentukan. Dominasi Mekongga yang bertahan di semua perlakuan menunjukkan bahwa hasil itu mencerminkan geometri spektral yang nyata. Dan ketiadaan validasi lapangan menunjukkan bahwa seluruhnya masih merupakan pernyataan tentang spektrum, bukan tentang peta. Menyampaikan keempat hal itu bersama-sama, tanpa menyembunyikan yang kurang menyenangkan, adalah satu-satunya cara agar hasil ini dapat dipakai secara bertanggung jawab.

11.1 Sebuah angka yang tidak masuk akal

Pekerjaan penguraian spektral (spectral unmixing) pada citra Sentinel-2 area Indramayu sudah berjalan sampai tahap akhir ketika sebuah angka muncul dan tidak dapat diabaikan: **nol persen**. Nol persen piksel padi berada di dalam *convex hull* endmember (endmember) SpecLib. Bukan angka kecil, bukan angka yang bisa dibulatkan menjadi "hampir nol", tetapi benar-benar nol — pada ketiga bidang kanal (band) yang diuji sekaligus.

Angka itu muncul dari pengujian yang sederhana. Untuk setiap piksel padi, nilai reflektansinya pada sepasang kanal diplot sebagai satu titik pada bidang dua dimensi. Kemudian lima endmember padi — Ciherang, IR64, Inpari32, Inpari32_WBC, dan Mekongga — juga diplot pada bidang yang sama. Lima titik itu membentuk sebuah poligon: itulah *convex hull*, selubung cembung, wilayah terkecil yang memuat seluruh endmember. Secara teori, setiap piksel yang merupakan campuran dari kelima varietas (variety) itu harus jatuh di dalam poligon tersebut. Itulah makna geometris dari model campuran linear [1,3].

Kenyataannya, dari 1.994.687 piksel yang dinyatakan padi oleh masker (mask) NDVI, tidak ada satu pun yang jatuh di dalam poligon itu pada bidang merah–inframerah dekat (B4–B8). Hal yang sama terjadi pada bidang red-edge2–inframerah dekat (B6–B8) dan red-edge1–inframerah dekat (B5–B8): **0,0 persen** pada ketiganya. Ketika diperiksa lebih rinci, rata-rata hanya **2,4 dari 9 kanal** nilai piksel padi yang berada di dalam rentang nilai endmember. Sisanya — lebih dari enam kanal dari sembilan — berada di luar rentang itu.

Angka ini menuntut penjelasan. Bila seluruh piksel padi berada di luar selubung endmember, maka secara formal tidak ada satu pun solusi campuran yang sah untuk piksel-piksel itu. Model campuran linear mengandaikan bahwa setiap piksel adalah kombinasi linear dari endmember dengan bobot yang tidak negatif dan berjumlah satu [1,2]. Bila piksel berada di luar hull, tidak ada kombinasi semacam itu yang dapat menghasilkan piksel tersebut. Algoritme *Fully Constrained Least Squares* (FCLS) yang dipakai tetap akan mengembalikan jawaban — karena ia memaksa kendala jumlah-satu dan non-negatif [2,11,12] — tetapi jawaban

itu adalah jawaban yang terdorong ke batas, bukan jawaban yang benar. Inilah gejala yang harus dijelaskan.

Bab ini adalah kisah investigasi tersebut. Ia disusun bukan sebagai laporan hasil, melainkan sebagai catatan penalaran: bagaimana sebuah gejala dirumuskan, bagaimana dugaan-dugaan disusun, bagaimana dugaan-dugaan itu diuji dan satu per satu ditolak, dan bagaimana akhirnya akar masalah yang sebenarnya ditemukan. Sebagaimana akan terlihat, pelajaran terpenting dari seluruh penyelidikan ini bukanlah jawabannya, melainkan cara berpikir yang menghasilkannya.

11.2 Mengapa hull kosong itu layak diselidiki

Sebelum masuk ke penyelidikan, perlu dijelaskan mengapa angka nol persen itu bukan sekadar keanehan yang boleh diabaikan.

Convex hull bukan sekadar hiasan geometris. Ia adalah fondasi dari hampir semua metode penguraian spektral. Konsep ini pertama dirumuskan untuk penguraian data hiperspektral oleh Boardman, yang menunjukkan bahwa endmember dari suatu pemandangan berada pada titik-titik sudut selubung cembung dari sebaran piksel [3]. Logikanya sederhana: bila setiap piksel adalah campuran, maka piksel yang murni — yang hanya memuat satu bahan — harus berada di tepi terluar sebaran, dan campuran selalu berada di antaranya. Karena itu selubung cembung dari seluruh piksel harus memuat seluruh endmember. Sebaliknya, bila endmember berada di luar selubung piksel, ada yang salah: entah endmember itu bukan endmember dari pemandangan tersebut, atau pikselnya bukan piksel yang seharusnya.

Dengan logika itu, hull yang kosong adalah sinyal yang serius. Ia berarti salah satu dari dua hal. **Kemungkinan pertama:** citra yang dianalisis memang tidak memuat objek yang diwakili endmember itu — dalam hal ini, mungkin citra yang dipakai tidak benar-benar menampilkan padi pada fase yang sesuai dengan endmember. **Kemungkinan kedua:** endmember yang dipakai memang tidak mewakili objek yang ada di citra — dalam hal ini, spektrum Speclib tidak cocok dengan padi yang sebenarnya tumbuh di Indramayu.

Kedua kemungkinan itu menjadi dua hipotesis yang harus diuji. Seluruh bab ini pada dasarnya adalah pengujian atas keduanya.

Perlu dicatat sejak awal bahwa kesimpulan akhir dari bab ini adalah: **kedua hipotesis itu salah.** Bukan citranya yang salah, dan bukan endmembernya yang salah. Yang menjadi akar masalah adalah sesuatu yang lebih mendasar dan lebih mudah terlewatkan: perbedaan sifat antara cara endmember diukur dan cara piksel satelit terbentuk. Tetapi kesimpulan itu hanya dapat dipercaya karena kedua hipotesis yang lebih sederhana telah diuji dan ditolak terlebih dahulu. Itulah nilai dari penyelidikan yang runtut.

11.3 Hipotesis pertama: fase citra salah

Hipotesis pertama datang dari temuan Bab 7, dan temuan itu cukup kuat untuk dijadikan dugaan utama.

Pada Bab 7 telah dibuktikan bahwa komposit (composite) citra Sentinel-2 yang dipakai pada analisis awal — komposit periode Mei sampai Agustus 2026 — ternyata diambil pada fase yang salah. Median tanggal pembungaan (heading) padi di area kajian adalah **22 Maret 2026**. Artinya komposit itu **mulai 39 hari setelah pembungaan median**. Ia sama sekali tidak memuat fase puncak.

Pengujian fase mengonfirmasi hal itu dengan gamblang. Ketika fase setiap piksel padi ditentukan untuk jendela komposit lama, hasilnya: 64,5 persen piksel berada pada fase vegetatif, 32,4 persen pada fase bera (fallow) atau persiapan, 1,1 persen pada fase generatif, dan **0,0 persen pada fase puncak atau heading**. Hanya 29,9 persen piksel yang puncak EVI-nya jatuh di dalam jendela komposit itu.

Sebaran kelas fase di atas dihitung dengan cara yang membandingkan EVI rata-rata di dalam jendela terhadap kurva penuh. Cara itu tidak stabil terhadap pergeseran jendela — kelasnya berubah pada 56,8 sampai 71,4 persen piksel ketika jendela digeser 20 sampai 40 hari — dan kelas puncaknya praktis kosong. Angka itu tetap sah sebagai bukti bahwa jendela lama duduk pada fase yang salah. Tetapi bila sebaran kelas fase hendak dipakai menarik kesimpulan agronomis, angka itu harus dihitung ulang dari tanggal yang diturunkan dari puncak EVI (Bab 15.8).

Dari sini muncul hipotesis yang masuk akal: **hull kosong terjadi karena citra dianalisis pada fase yang salah.** Endmember SpecLib mewakili padi pada fase puncak. Bila citra yang dianalisis memuat padi pada fase vegetatif dan bera, maka spektrum piksel tidak akan cocok

dengan endmember, dan hull pun menjadi kosong. Ini penjelasan yang elegan dan sangat mungkin benar.

Hipotesis itu dirumuskan secara eksplisit: *bila citra diganti dengan komposit yang diambil pada jendela pembungaan yang benar, maka hull akan terisi.*

Untuk mengujinya, fenologi (phenology) MODIS dipakai untuk menentukan jendela tanggal yang tepat. Sebagaimana diuraikan pada Bab 7, sebaran tanggal heading memiliki persentil (percentile) 25 pada 6 Maret 2026 dan persentil 75 pada 23 April 2026. Dari rentang itu ditetapkan jendela yang benar: **24 Februari sampai 3 Mei 2026**, yaitu rentang antara persentil 25 dan persentil 75 tanggal pembungaan. Komposit baru dibangun pada jendela itu, dan penguraian diulang.

Hasil pengujian membawa dua kabar sekaligus, dan keduanya penting.

Kabar baiknya: jendela yang benar memang mengubah hasil secara nyata. Fraksi (fraction) varietas bergeser cukup besar. Pada jendela lama, fraksi Mekongga adalah 0,4293 (dominan pada 62,7 persen piksel). Pada jendela heading, fraksi itu naik menjadi 0,5546 (dominan pada 74,5 persen piksel). Fraksi Inpari32 turun dari 0,1620 menjadi 0,0879. Fraksi Inpari32_WBC hampir tidak berubah, dari 0,2461 menjadi 0,2396. Jadi memperbaiki jendela tanggal memang memperbaiki sesuatu: ia menghilangkan pencampuran fase yang merusak asumsi model campuran linear.

Kabar buruknya: hipotesis intinya **ditolak**. Setelah jendela diperbaiki ke fase heading, hull **tetap 0,0 persen**. Tidak ada satu pun piksel padi yang berpindah ke dalam selubung endmember. Gejala yang ingin dijelaskan sama sekali tidak berubah.

Bahkan ada tanda yang mengkhawatirkan. Pada jendela lama, persentase piksel ekstrem (extreme pixel) hanya 0,004 persen. Pada jendela heading, angka itu melonjak menjadi **3,815 persen** — hampir seribu kali lebih besar. Piksel ekstrem adalah piksel yang solusinya terdorong ke batas kendala, dan sebagaimana ditegaskan pada kerangka kerja, naiknya piksel ekstrem selalu menandakan bahwa endmember tidak mencakup citra. Jadi memperbaiki jendela bukan hanya gagal mengisi hull; ia justru memperkuat tanda bahwa ada sesuatu yang lebih dalam yang salah.

Dengan demikian hipotesis pertama **ditolak**: fase citra yang salah bukan penyebab hull kosong. Ia adalah masalah nyata — sebagaimana telah dibahas pada Bab 7 — tetapi ia masalah yang berbeda. Memperbaiki jendela tanggal memang perlu, tetapi ia tidak menyentuh akar dari gejala yang sedang diselidiki.

11.4 Hipotesis kedua: endmember salah

Bila citranya sudah benar dan hull tetap kosong, maka dugaan berikutnya mengarah ke sisi yang lain: **mungkin endmembernya yang salah.**

Hipotesis ini lebih tidak nyaman, karena ia menyentuh pekerjaan yang paling dipercaya. Endmember SpecLib ITS adalah hasil pengukuran spektrometri langsung di lapangan, dikurangi menjadi lima kelas padi melalui reduksi median dan pemetaan Gaussian. Bila endmember itu yang salah, maka seluruh rantai analisis berdiri di atas fondasi yang retak.

Hipotesis kedua dirumuskan sebagai berikut: *bila endmember SpecLib tidak mewakili padi yang sebenarnya ada di citra, maka bentuk spektrumnya akan berbeda dari spektrum piksel padi nyata.*

Untuk mengujinya, digunakan uji **korelasi bentuk**. Caranya: ambil sekelompok piksel yang paling murni — piksel yang paling dekat ke satu varietas tertentu dan paling sedikit tercampur — kemudian bandingkan *bentuk* kurva spektrumnya dengan bentuk kurva endmember SpecLib. Yang dibandingkan bukan nilai absolutnya, melainkan polanya: apakah naik-turun reflektansi (reflectance) dari satu kanal ke kanal berikutnya mengikuti pola yang sama. Ukuran yang dipakai adalah korelasi Pearson antara kedua vektor spektrum, setelah masing-masing dinormalisasi skalanya. Bila korelasinya tinggi, artinya bentuk kurvanya sama — hanya berbeda skala. Bila korelasinya rendah, artinya endmember memang mewakili objek yang berbeda.

Hasil pengujiannya tegas dan seragam:

Varietas	n piksel murni	koreksi skala k	Korelasi bentuk
Ciherang	10.775	0,636	0,9910
IR64	19.867	0,574	0,9980
Inpari32	64.034	0,591	0,9929
Inpari32_WBC	306.667	0,297	0,9940

Varietas	n piksel murni	koreksi skala k	Korelasi bentuk
Mekongga	1.337.589	0,568	0,9929

Seluruh korelasi berada di antara **0,991 dan 0,998**. Nilai setinggi itu berarti bentuk kurva endmember SpecLib hampir identik dengan bentuk kurva piksel padi yang paling murni di citra. Perbedaannya hanya pada skala — dan skala itu memang berbeda, sebagaimana akan dijelaskan pada bagian berikutnya. Dengan kata lain: **endmember SpecLib benar**. Ia memang mewakili padi yang tumbuh di Indramayu.

Hipotesis kedua pun **ditolak**. Bukan endmembernnya yang salah.

Ada satu pengujian independen yang memperkuat penolakan ini, dan pengujian itu datang dari arah yang sama sekali berbeda. Pada Bab 12 akan dibahas secara panjang apa yang disebut *Pure Pixel Index* (PPI) — sebuah metode yang mengekstrak endmember langsung dari citra, tanpa menggunakan pustaka spektral sama sekali. Metode itu bekerja murni dari geometri sebaran piksel, mencari titik-titik yang paling ekstrem [3]. Bila endmember SpecLib salah, maka endmember hasil ekstraksi PPI — yang berasal dari citra itu sendiri — seharusnya berbeda jauh.

Kenyataannya tidak. Ketika PPI dijalankan pada citra ini, endmember yang dihasilkan dicocokkan dengan endmember SpecLib, dan hasilnya: varietas Mekongga hanya terpaut **2,8 derajat sudut spektral (spectral angle)** dari endmember SpecLib, dengan korelasi bentuk **0,9988**. Empat endmember lain yang dihasilkan PPI juga cocok dengan varietas SpecLib, dengan sudut antara 4,0 dan 14,3 derajat. Jadi dua metode yang sepenuhnya independen — pustaka lapangan dan ekstraksi citra — menghasilkan endmember yang sepakat. Ini menutup kemungkinan bahwa endmember SpecLib salah.

Dengan kedua hipotesis utama ditolak, penyelidikan berada di titik yang tidak nyaman. Citranya benar. Endmembernnya benar. Tetapi hull tetap kosong. Sesuatu yang lain harus menjelaskannya.

11.5 Akar masalah: perbedaan sifat pengukuran

Setelah kedua hipotesis sederhana ditolak, penyelidikan bergeser dari pertanyaan "apa yang salah?" menjadi pertanyaan yang lebih tepat: "**apa yang sebenarnya terjadi?**" Perhatikan bahwa pertanyaan itu tidak lagi

mengandaikan adanya kesalahan. Ia mengandaikan bahwa gejala itu mungkin memiliki penjelasan yang sah.

Untuk menjawabnya, dilakukan pemeriksaan terhadap nilai reflektansi itu sendiri, kanal demi kanal, tanpa asumsi. Kanal inframerah dekat (B8) dipilih karena kanal itu paling menentukan bentuk kurva vegetasi, dan karena seluruh endmember padi memiliki nilai tinggi pada kanal itu.

Hasilnya adalah kunci dari seluruh investigasi:

	Nilai B8 (NIR)
Rentang endmember SpecLib	0,5927 – 0,8464
Citra padi, jendela heading: p50	0,2884
Citra padi: p90	0,3752
Citra padi: p99	0,4444
Piksel dengan NIR $\geq$ 0,5927	177 dari 1.994.687 (0,009%)
Rata-rata piksel p99 ke atas	0,4730

Bacalah tabel itu perlahan, karena di dalamnya terletak seluruh jawabannya.

Endmember terendah memiliki nilai NIR 0,5927 — yaitu endmember Inpari32, yang kebetulan adalah yang tergelap dari kelima varietas. Sementara itu, nilai NIR median piksel padi di citra hanya 0,2884 — **kurang dari setengah** nilai endmember tergelap. Bahkan piksel pada persentil 99, yaitu piksel yang paling terang dari satu persen teratas, hanya mencapai 0,4444. Angka itu masih **di bawah** endmember tergelap. Dan ketika dihitung berapa banyak piksel yang mencapai atau melewati endmember tergelap itu, jawabannya: hanya **177 piksel dari 1.994.687**, atau **0,009 persen**.

Inilah mengapa hull kosong. Hull kosong bukan karena citranya salah, dan bukan karena endmembernya salah, melainkan karena **dua hal itu mengukur objek yang berbeda**.

Endmember SpecLib diukur dengan spektrometri pada **kanopi (canopy) padi saja** — pada petak contoh, dengan instrumen diarahkan ke dedaunan padi. Yang terukur adalah reflektansi daun dan kanopi secara langsung. Sebaliknya, satu piksel Sentinel-2 berukuran 30 × 30 meter

mencakup sekitar **900 meter persegi** permukaan. Dalam luasan sebesar itu, sawah tidak pernah hanya berisi kanopi padi. Ia selalu memuat tanah yang terlihat di antara rumpun, air genangan (inundation), pematang, celah antar baris tanaman, dan sudut-sudut yang tidak tertutup daun. Semua bahan yang lebih gelap itu — tanah dan air terutama — menyerap sebagian cahaya inframerah dekat dan menekan nilai reflektansi rata-rata piksel.

Akibatnya, satu piksel satelit selalu merupakan campuran antara kanopi padi dan bahan-bahan lain yang ada di dalam kotak 900 meter persegi itu. Dan campuran itu selalu lebih gelap daripada kanopi murni. Karena endmember diukur pada kanopi murni, nilainya selalu lebih tinggi daripada piksel yang memuat campuran. Jarak antara keduanya bukan kesalahan — ia adalah **konsekuensi tak terhindarkan dari perbedaan skala pengukuran**.

Inilah yang dalam kerangka kerja disebut **efek pencampuran resolusi**. Ia bukan cacat data, dan bukan kesalahan endmember. Ia adalah kenyataan fisik: piksel satelit mengukur rata-rata, sedangkan endmember mengukur objek tunggal.

11.6 Mengapa penskalaan tidak menyelesaikannya

Setelah akar masalah dipahami, muncul gagasan yang tampak logis. Bila masalahnya adalah perbedaan skala — endmember terlalu tinggi, piksel terlalu rendah — maka bukankah solusinya adalah **memperkecil endmember** agar cocok dengan piksel? Cukup kalikan seluruh endmember dengan sebuah faktor, dan hull akan terisi.

Gagasan ini diuji, dan hasilnya justru membuka pelajaran yang lebih dalam. Ketika endmember dikalikan dengan berbagai faktor skala, cakupan hull (hull coverage) memang berubah:

Faktor k	Persentase piksel dalam hull (B4–B8)
0,30	8,6%
0,40	29,6% (optimum)
0,50	15,6%
0,60	2,6%
1,00	0,0%

Pada faktor 0,40, cakupan hull mencapai optimumnya, yaitu 29,6 persen — jauh lebih baik daripada nol. Sepintas, masalahnya terselesaikan.

Tetapi pengujian lebih lanjut mengungkap jebakan. Algoritme FCLS dengan kendala jumlah-satu bersifat **invarian skala (scale invariance)** [2]. Artinya, mengalikan seluruh endmember dengan faktor yang sama **tidak mengubah fraksi yang dihasilkan sama sekali**. Fraksi adalah perbandingan antar-kelas, dan perbandingan itu tidak berubah ketika semua endmember diperkecil dengan faktor yang sama. Yang berubah hanyalah skala solusi, bukan komposisinya. Jadi cakupan hull yang naik itu **tidak berarti apa-apa** bagi hasil akhir.

Yang lebih buruk, penskalaan merusak sesuatu yang penting. Ketika endmember diperkecil sementara derau (noise) citra tetap, jarak antar-varietas menyusut, sedangkan derau tidak. Rasio sinyal terhadap derau pun memburuk. Hasil pengukuran:

Pasangan varietas	Jarak asli	Jarak setelah koreksi vektor	Perubahan
Ciherang–IR64	0,1222	0,0649	–46,9%
Ciherang–Mekongga	0,2731	0,1171	–57,1%
IR64–Mekongga	0,2140	0,0855	–60,0%

Jarak antar-varietas menyusut antara 46,9 dan 60,0 persen. Padahal jarak itulah yang memungkinkan pemisahan. Varietas yang semula dapat dibedakan kini tenggelam dalam derau. Akibatnya, akurasi pemisahan jatuh dari 91,1 persen menjadi 79,5 persen pada penskalaan skalar $k=0,40$. Bahkan koreksi per kanal — yang secara teori lebih benar karena rasio antar-kanal memang tidak seragam — menghasilkan akurasi 81,6 persen, juga lebih buruk daripada tanpa koreksi sama sekali.

Perhatikan bahwa rasio singular (singular-value ratio) tidak berubah oleh koreksi ini: tetap 410,8, bahkan 411,8 setelah koreksi vektor. Artinya masalahnya bukan pada geometri endmember. Yang rusak adalah margin antara jarak kelas dan derau.

Pelajaran dari bagian ini penting untuk diingat: **gejala hull kosong dapat "diperbaiki" tanpa memperbaiki apa pun**. Cakupan hull bisa dinaikkan dari nol menjadi 29,6 persen, tetapi hasil akhirnya justru lebih buruk. Ini menegaskan hal yang telah ditegaskan pada kerangka kerja: hull adalah **diagnostik**, bukan sasaran. Ia berguna untuk memahami masalah, tetapi ia bukan sesuatu yang boleh dikejar demi dirinya sendiri.

11.7 Konfirmasi lintas-sensor: Landsat 9

Sampai titik ini, seluruh penyelidikan bertumpu pada satu sensor. Pertanyaan yang wajar muncul sebelum kesimpulan diambil: **bagaimana bila masalah ini khas Sentinel-2?** Bila hull kosong hanya terjadi pada data Sentinel-2, mungkin ada sesuatu pada sensor itu — karakteristik kanalnya, pemrosesannya, atau cara datanya diunduh — yang menyebabkannya. Selama kemungkinan itu terbuka, kesimpulan bahwa akar masalahnya adalah perbedaan sifat pengukuran belum dapat dipegang sepenuhnya.

Untuk menutup kemungkinan itu, dilakukan pengujian lintas-sensor dengan **Landsat 9**. Scene yang dipakai adalah citra tanggal **23 Maret 2026** — hanya sehari setelah tanggal pembungaan median 22 Maret 2026 — dengan tutupan awan 13,4 persen, pada path/row 121/065. Skala radiometrik Collection 2 dikonversi dengan rumus $DN \times 0,0000275 - 0,2$, sesuai prosedur yang telah dibahas pada Bab 6.

Sebelum pengujian, satu hal harus diperiksa lebih dahulu. Scene Landsat 9 yang dipilih ternyata **hanya menutupi 36,5 persen** dari area kajian; sisanya bernilai nol. Bila hal ini tidak diperiksa, hasilnya akan menyesatkan: piksel nol akan membuat indeks vegetasi membagi dengan hampir nol, dan nilai NDVI meledak menjadi angka yang tidak bermakna. Setelah piksel nol dibuang, irisan dengan area Sentinel-2 adalah 36,0 persen, dan perbandingan dilakukan pada **333.818 piksel** yang benar-benar bertumpang-tindih.

Hasil pertama adalah kesepakatan kedua sensor. NDVI Landsat 9 bernilai 0,6434 dengan simpangan baku 0,2627; NDVI Sentinel-2 bernilai 0,5755 dengan simpangan baku 0,2787. Korelasi keduanya **0,839**, dengan RMSE 0,1687 dan bias median -0,0505. Hubungan keduanya mengikuti regresi $S2 = 0,890 \times L9 + 0,003$ — kemiringan mendekati satu dan intersep mendekati nol. Artinya kedua sensor mengukur hal yang sama, dengan perbedaan sistematis yang kecil. Masker padi yang dibangun dari masing-masing sensor pun sepakat: presisi 90,1 persen, recall 98,1 persen, dan F1 93,9 persen.

Hasil kedua adalah yang paling penting, dan hasil itu mengubah status kesimpulan secara mendasar. Ketika uji convex hull yang sama dijalankan pada data Landsat 9, hasilnya **identik dengan Sentinel-2**: nol persen piksel padi berada di dalam hull, pada ketiga bidang kanal yang diuji

— merah–inframerah dekat, hijau–inframerah dekat, dan biru–inframerah dekat.

Kesimpulan dari pengujian lintas-sensor ini tegas. Hull yang kosong **bukan akibat karakteristik kanal Sentinel-2, dan bukan akibat kesalahan pemrosesan pada sensor itu.** Kondisi itu bersifat universal: ia terjadi pada sensor mana pun, karena penyebabnya bukan sensor. Penyebabnya, sebagaimana telah ditetapkan pada bagian sebelumnya, adalah perbedaan mendasar antara cara endmember diukur — pada kanopi murni dengan spektoradiometer — dan cara piksel satelit terbentuk — sebagai rata-rata 900 meter persegi permukaan yang selalu memuat tanah, air, dan pematang.

Sebelum pengujian ini, hull yang kosong masih dapat diduga sebagai keanehan satu sensor. Setelah pengujian ini, dugaan itu tertutup. Yang tersisa hanyalah penjelasan yang benar.

11.8 Pelajaran metodologis: diagnostik bukan tujuan

Seluruh penyelidikan ini dapat diringkas dalam satu tabel yang memuat jalannya penalaran:

Tahap	Dugaan	Pengujian	Hasil
Gejala	Hull kosong: 0,0% pada tiga bidang kanal	—	—
Hipotesis 1	Fase citra salah	Jendela heading (24 Feb – 3 Mei 2026)	Ditolak — hull tetap 0,0%
Hipotesis 2	Endmember salah	Korelasi bentuk piksel murni vs Speclib	Ditolak — korelasi 0,991– 0,998
Akar masalah	Perbedaan sifat pengukuran	Pemeriksaan nilai NIR kanal demi kanal	Diterima — hanya 0,009% piksel mencapai endmember tergelap
Konfirmasi	Khas satu sensor?	Uji lintas-sensor Landsat 9	Ditolak — hull juga 0,0%

Dari tabel itu, beberapa pelajaran metodologis dapat ditarik.

Pelajaran pertama: gejala yang aneh menuntut penjelasan, bukan pembetulan. Reaksi yang wajar ketika melihat hull kosong adalah segera memperbaikinya. Tetapi hull kosong ternyata bukan cacat yang perlu diperbaiki — ia adalah **kenyataan yang perlu dipahami**. Bila reaksi pertama adalah memperbaikinya, maka upaya akan diarahkan pada penskalaan endmember, penambahan kelas, dan ekstraksi piksel murni (pure pixel) — empat pendekatan yang, sebagaimana akan dibahas pada Bab 12, semuanya terbukti gagal. Memahami gejala terlebih dahulu mencegah empat jalan buntu itu ditempuh.

Pelajaran kedua: hipotesis harus diuji sampai ditolak atau diterima, bukan diasumsikan. Kedua hipotesis utama pada bab ini — fase salah dan endmember salah — sama-sama tampak masuk akal. Yang pertama bahkan didukung temuan kuat dari Bab 7. Tetapi keduanya ternyata salah, dan itu hanya dapat diketahui karena keduanya diuji secara langsung. Bila hipotesis pertama diterima begitu saja tanpa pengujian, seluruh analisis akan berhenti pada kesimpulan yang keliru: bahwa memperbaiki jendela tanggal akan mengisi hull. Pengujianlah yang mengungkapkan bahwa jendela yang benar justru menaikkan piksel ekstrem dari 0,004 persen menjadi 3,815 persen — tanda bahwa masalahnya lebih dalam.

Pelajaran ketiga: diagnostik bukan tujuan. Ini pelajaran paling penting dari seluruh bab, dan alasan mengapa bab ini diberi judul sebagaimana adanya. *Convex hull* adalah alat diagnostik yang sangat berguna. Ia memberitahu kita bahwa ada sesuatu yang tidak sesuai antara endmember dan citra. Ia mengarahkan penyelidikan ke arah yang benar. Tetapi begitu ia dijadikan **sasaran** — begitu tujuannya menjadi "membuat hull terisi" — maka alat itu berbalik melawan kita. Cakupan hull dapat dinaikkan dari 0 persen menjadi 29,6 persen dengan penskalaan, atau bahkan 51,6 persen dengan ekstraksi piksel murni, tetapi setiap kenaikan itu disertai kemunduran hasil yang nyata. Hull yang terisi bukan tanda keberhasilan; ia bisa jadi tanda bahwa kita telah menyesatkan diri sendiri.

Diagnostik yang benar tidak dijadikan tujuan, melainkan dipakai untuk menjawab pertanyaan, lalu ditinggalkan setelah pertanyaannya terjawab. Hull sudah menjawab pertanyaannya pada bab ini: ia menunjukkan bahwa ada ketidaksesuaian antara endmember dan citra, dan jawaban itu mengarah pada penemuan akar masalah yang sebenarnya.

Setelah perannya selesai, hull tidak lagi menjadi ukuran apa pun. Yang menjadi ukuran adalah akurasi pemisahan, piksel ekstrem, dan konsistensi urutan dominasi — sebagaimana ditetapkan pada kerangka kerja.

Pelajaran keempat: satu sensor tidak cukup untuk menyimpulkan. Kesimpulan bahwa hull kosong adalah kenyataan universal baru dapat dipegang setelah diuji pada sensor kedua. Bila hanya Sentinel-2 yang diuji, selalu ada kemungkinan bahwa kesimpulan itu khas sensor tersebut. Pengujian lintas-sensor menutup kemungkinan itu, dan sekaligus memberi keyakinan bahwa data yang dipakai memang sah. Kebiasaan memvalidasi lintas sensor sebaiknya dibakukan, bukan dijadikan pengecualian.

11.9 Apa yang akhirnya diketahui

Investigasi pada bab ini menghasilkan kesimpulan yang, meskipun sederhana, mengubah cara seluruh pekerjaan ini dipahami.

Pertama, hull kosong bukan kesalahan. Ia adalah konsekuensi tak terhindarkan dari perbedaan skala pengukuran antara endmember dan piksel satelit. Endmember SpecLib diukur pada kanopi padi murni, sedangkan satu piksel Sentinel-2 berukuran 30 meter selalu memuat tanah, air, dan pematang yang menekan nilai reflektansinya. Karena itu piksel selalu lebih gelap daripada endmember, dan selalu berada di luar hull. Hanya 0,009 persen piksel yang mencapai nilai endmember tergelap.

Kedua, endmember SpecLib terbukti benar. Korelasi bentuk antara spektrum piksel padi paling murni dan endmember SpecLib berada di antara 0,991 dan 0,998. Pengujian independen dengan ekstraksi piksel murni mengonfirmasi hal yang sama: varietas Mekongga hanya terpaut 2,8 derajat sudut spektral dari endmember SpecLib. Jadi endmember yang dipakai memang mewakili padi nyata di lapangan.

Ketiga, hull kosong bersifat universal. Ia terjadi pada Sentinel-2 dan pada Landsat 9 sekaligus, sehingga tidak dapat dijelaskan sebagai akibat karakteristik sensor atau kesalahan pemrosesan.

Keempat, dan yang paling penting untuk pekerjaan selanjutnya: **hull 0 persen harus diterima dan dilaporkan apa adanya.** Ia bukan cacat yang menunggu diperbaiki, melainkan sifat dasar dari data yang digunakan. Setiap upaya untuk "mengisi" hull akan merusak akurasi, sebagaimana

akan ditunjukkan secara panjang pada Bab 12. Yang benar dilakukan adalah menerima kenyataan itu, melaporkannya secara terbuka kepada pengguna, dan mengarahkan upaya pada hal-hal yang benar-benar dapat diperbaiki: endmember per fase tumbuh, sensor yang lebih baik, dan — yang paling menentukan — data lapangan sebagai acuan kebenaran.

Bab ini berakhir bukan dengan sebuah angka yang diperbaiki, melainkan dengan sebuah pemahaman yang diperoleh. Hull tetap kosong sebagaimana sebelumnya. Tetapi kini kita tahu mengapa ia kosong, dan mengetahui mengapa sesuatu terjadi jauh lebih berharga daripada mengubahnya tanpa memahami. Di situlah letak nilai dari sebuah investigasi yang terbuka.

BAB XII EMPAT PENDEKATAN YANG TERBUKTI GAGAL

12.1 Mengapa bab ini ditulis

Buku ini sampai pada bagian yang paling tidak nyaman, sekaligus paling berguna. Bab-bab sebelumnya melaporkan apa yang bekerja: endmember (endmember) SpecLib, FCLS tervektor, jendela tanggal dari fenologi (phenology), dan masker (mask) padi gabungan. Bab ini melaporkan yang sebaliknya — empat pendekatan perbaikan yang, satu per satu, tampak masuk akal secara teori, dikerjakan dengan sungguh-sungguh, dan seluruhnya berakhir gagal.

Perlu ditegaskan sejak awal bahwa keempat pendekatan ini bukanlah gagasan yang naif. Masing-masing berangkat dari prinsip yang sah dalam literatur penguraian spektral (spectral unmixing). Model campuran linear memang mengandaikan bahwa seluruh benda penyusun diwakili dalam himpunan endmember [1]. Metode ekstraksi geometris memang dirancang untuk menemukan endmember dari data itu sendiri [3]. Variabilitas endmember pun masalah yang diakui dan dibahas panjang dalam tinjauan Somers dan rekan [9]. Yang gagal bukanlah teori-teorinya, melainkan penerapannya pada kasus yang punya sifat khas: jarak antar-kelas yang tipis, dan endmember yang diukur pada skala yang berbeda dari piksel.

Bab ini ada bukan karena laboratorium senang mencatat kekalahan. Alasannya praktis: keempat jalan buntu ini sudah memakan waktu, dan tidak satu pun tampak buntu dari luar. Ketika seseorang melihat bahwa seluruh piksel padi berada di luar convex hull endmember, refleksi pertama yang wajar adalah memperbaiki keadaan itu — menggeser endmember, menambah kelas, mencari endmember yang lebih cocok dengan citra. Refleksi itu benar secara naluri, tetapi salah secara teknis. Kesalahannya baru terlihat setelah pengujian yang memakan waktu berminggu-minggu. Bab ini ditulis supaya orang berikutnya tidak perlu menempuh jalan yang sama untuk sampai pada kesimpulan yang sama.

Yang dilaporkan di sini bukanlah empat kesalahan yang berbeda-beda, melainkan **empat wajah dari satu masalah yang sama**. Setiap pendekatan berangkat dari gejala yang sama — cakupan hull (hull coverage) nol persen, RMSE yang tampak memburuk — dan setiap pendekatan memperbaiki gejala itu. Yang tidak berhasil adalah menghasilkan pemetaan varietas (variety) yang lebih baik. Justru

sebaliknya: setiap perbaikan gejala disertai kemunduran hasil yang sesungguhnya. Pola itu akan dibahas di akhir bab — pola itulah inti pelajarannya.

Sebelum masuk ke masing-masing pendekatan, perlu ditegaskan satu hal mengenai keterbukaan pelaporan. Seluruh angka di bab ini berasal dari pengukuran langsung pada 1.994.687 piksel padi di area kajian, bukan dari perkiraan atau contoh ilustratif. Bila sebuah pendekatan dilaporkan gagal, yang dimaksud adalah ia gagal menurut ukuran yang paling menentukan — akurasi pemisahan varietas — meskipun pada ukuran lain ia tampak berhasil. Perbedaan antara kedua jenis ukuran itulah yang akan dibahas pada Bab 13.

12.2 Titik tolak: endmember apa adanya

Untuk menilai keempat pendekatan perbaikan, diperlukan sebuah titik tolak. Titik tolak dalam pekerjaan ini adalah **endmember Speclib ITS apa adanya** — lima kelas varietas padi, hasil reduksi median dan pemetaan Gaussian, dipakai tanpa perubahan skala, tanpa penambahan kelas, tanpa koreksi. Endmember ini diukur dari kanopi (canopy) padi menggunakan spektorradiometer, sehingga merepresentasikan spektrum padi itu sendiri.

Performa titik tolak ini dilaporkan secara lengkap pada tabel berikut.

Pendekatan	RMSE	Cakupan hull	Piksel ekstrem	Akurasi
Speclib apa adanya	179,4%	0%	8,9%	91,1%
Penskalaan skalar $k=0,40$	31,7%	16,8%	3,8%	79,5%
Koreksi per kanal (vektor)	46,2%	12,7%	3,7%	81,6%
Ekstraksi piksel murni (PPI)	23,0%	51,6%	17,4%	fraksi kacau

Tabel ini paling penting dalam seluruh buku ini; pembaca sebaiknya membacanya perlahan. Perhatikan kolom RMSE: titik tolak memiliki RMSE paling buruk — 179,4 persen, angka yang bahkan melampaui seratus persen dan tampak seperti kegagalan total. Ketiga pendekatan perbaikan menekan angka itu secara drastis: 31,7 persen, 46,2 persen, dan

23,0 persen. Bila RMSE dipakai sebagai satu-satunya ukuran keberhasilan, ketiga pendekatan itu jelas menang.

Sekarang perhatikan kolom akurasi: titik tolak justru menang. Akurasi pemisahan endmember apa adanya adalah **91,1 persen**, sedangkan ketiga perbaikan hanya mencapai 79,5 persen dan 81,6 persen. PPI menghasilkan fraksi (fraction) yang kacau, sehingga akurasinya bahkan tidak dapat dilaporkan sebagai satu angka tunggal. Titik tolak yang tampak paling buruk pada RMSE adalah titik tolak yang paling baik pada hasil yang sesungguhnya.

Angka 91,1 persen itu sendiri berasal dari matriks kekeliruan (confusion matrix) piksel murni (pure pixel), sebagaimana dijelaskan pada Bab 10. Pada derau (noise) reflektansi (reflectance) 0,010, empat dari lima varietas terpisah hampir sempurna: Ciherang, Inpari32_WBC, dan Mekongga mencapai 100 persen, sedangkan Inpari32 mencapai 96,1 persen. Satu-satunya varietas yang bermasalah adalah IR64, dengan akurasi 59,7 persen, karena 28,9 persen pikselnya salah dikenali sebagai Ciherang dan 11,4 persen sebagai Inpari32. Kegagalan IR64 itu sendiri adalah batas fisik, bukan cacat metode: jarak spektral (spectral distance) antara IR64 dan Ciherang hanya 0,1222, terpendek di antara semua pasangan varietas.

Yang perlu ditegaskan: endmember SpecLib ini **benar**. Kalibrasi bentuk antara spektrum piksel padi yang paling murni di citra dengan endmember SpecLib memberi korelasi 0,991 sampai 0,998. Artinya, bentuk kurva endmember memang sesuai dengan padi nyata yang terekam satelit. Ekstraksi piksel murni, yang dijalankan secara independen, mengonfirmasi hal yang sama: endmember Mekongga hasil ekstraksi hanya berjarak sudut spektral (spectral angle) 2,8 derajat dari endmember SpecLib. Jadi persoalannya bukan pada endmember, dan justru itulah yang membuat keempat pendekatan perbaikan berikut tampak masuk akal sekaligus menyesatkan.

12.3 Pendekatan pertama: penskalaan skalar $k=0,40$

Gejala yang memicu pendekatan pertama sudah dibahas panjang pada Bab 11. Seluruh piksel padi berada di luar convex hull endmember SpecLib. Rata-rata hanya **2,4 dari 9 kanal (band)** piksel padi yang nilainya jatuh di dalam rentang endmember; pada bidang merah–inframerah dekat,

red-edge1–inframerah dekat, dan red-edge2–inframerah dekat, cakupan hull adalah **0,0 persen** pada ketiganya.

Akar masalahnya terukur dan jelas. Endmember SpecLib memiliki nilai kanal inframerah dekat antara 0,5927 dan 0,8464. Citra padi pada jendela heading hanya mencapai nilai tengah 0,2884, persentil (percentile) 90 sebesar 0,3752, dan persentil 99 sebesar 0,4444; bahkan rata-rata piksel di atas persentil 99 hanya 0,4730 — masih jauh di bawah endmember tergelap. Dari 1.994.687 piksel padi, hanya **177 piksel** — 0,009 persen — yang nilai inframerah dekatnya mencapai 0,5927.

Kesenjangan ini muncul karena endmember dan piksel diukur pada skala yang berbeda. Endmember diukur dari kanopi padi saja, sedangkan satu piksel Sentinel-2 seluas kira-kira 900 meter persegi selalu memuat tanah, air, pematang, dan celah antar rumpun. Efek pencampuran resolusi ini menekan seluruh nilai reflektansi piksel di bawah nilai kanopi murni.

Refleks pertama yang wajar adalah: kalau begitu, kecilkan endmember supaya cocok. Endmember dikalikan dengan satu faktor skalar k , lalu faktor itu dicari dengan menyapu beberapa nilai untuk melihat mana yang memberi cakupan hull terbaik. Hasil sapuan itu sebagai berikut.

Faktor k	% dalam hull (B4–B8)
0,30	8,6%
0,40	29,6% (optimum)
0,50	15,6%
0,60	2,6%
1,00	0,0%

Cakupan hull naik dari nol pada $k=1,00$ menjadi puncaknya 29,6 persen pada $k=0,40$, lalu turun lagi ketika k diperbesar. Nilai $k=0,40$ tampak seperti penemuan: sebuah faktor tunggal yang mengisi hull dan memperbaiki galat.

Tetapi hasilnya mengecewakan. Ketika penskalaan $k=0,40$ diterapkan pada penguraian yang sesungguhnya, RMSE turun dari 179,4 persen menjadi **31,7 persen** — perbaikan hampir enam kali lipat; akurasi pemisahan varietas justru turun dari 91,1 persen menjadi **79,5 persen**. Turun hampir dua belas poin bukanlah perbaikan; itu kemunduran yang disamarkan oleh angka galat yang membaik.

Sebabnya bukan kebetulan, dan sudah dijelaskan pada Bab 3. FCLS dengan kendala jumlah-satu **invarian terhadap penskalaan seragam** [2,11,12]. Bila seluruh matriks endmember dikalikan dengan konstanta k , solusi fraksi optimal tidak berubah sama sekali. Yang berubah hanyalah nilai galatnya, karena selisih antara spektrum piksel dan endmember yang diperkecil menjadi lebih kecil. Jadi fraksi yang timbul dari penskalaan seharusnya identik dengan fraksi endmember apa adanya. Mengapa akurasinya lalu turun?

Jawabannya ada pada derau. Penskalaan memang tidak mengubah perbandingan antar-endmember, tetapi ia mengecilkan seluruh endmember tanpa mengecilkan derau citra. Akibatnya rasio antara jarak antar-varietas dan derau memburuk; kalibrasi bentuk menunjukkan bahwa setiap varietas memang memiliki faktor optimalnya sendiri — Ciherang 0,636, IR64 0,574, Inpari32 0,591, Inpari32_WBC 0,297, dan Mekongga 0,568. Faktor-faktor itu tidak seragam, sehingga satu nilai k tunggal tidak mungkin cocok untuk semua. Yang lebih penting, mengecilkan endmember membuat perbedaan antar-varietas yang sudah tipis menjadi lebih tipis lagi — dan perbedaan yang tipis itulah yang tenggelam di dalam derau. Bab ini akan kembali pada mekanisme ini ketika membahas pendekatan ketiga.

12.4 Pendekatan kedua: penambahan kelas non-padi

Pendekatan kedua berangkat dari diagnosis yang berbeda. Bila hull kosong, mungkin masalahnya bukan pada skala endmember, melainkan pada kelengkapan endmember. Piksel sawah nyata memuat air dan tanah; mengapa kedua benda itu tidak dimasukkan sebagai kelas dalam model? Bila air dan tanah diberi endmember sendiri, piksel yang selama ini berada di luar hull karena memuat keduanya akan tertarik ke dalam.

Secara teori, penalaran ini kuat. Model campuran linear pada Bab 2 memang mengasumsikan bahwa seluruh benda penyusun harus ada dalam himpunan endmember. Bila air dan tanah tidak diwakili, model terpaksa menjelaskan bagian piksel yang berasal dari keduanya menggunakan endmember padi — dan itu memang mendistorsi hasil.

Dua kelas non-padi ditambahkan ke dalam lima kelas padi, sehingga menjadi tujuh kelas. Hasilnya diukur pada fraksi setiap varietas padi.

Varietas	5 kelas	7 kelas (+air, tanah)	Selisih
Ciherang	0,0849	0,0911	+7,3%
IR64	0,0777	0,0458	-41,1%
Inpari32	0,1620	0,0837	-48,3%
Inpari32_WBC	0,2461	0,1305	-47,0%
Mekongga	0,4293	0,3807	-11,3%

Angka-angka itu berbicara sendiri. Dua kelas tambahan membuat tiga varietas kehilangan hampir separuh fraksinya: IR64 turun 41,1 persen, Inpari32 turun 48,3 persen, dan Inpari32_WBC turun 47,0 persen. Hanya Ciherang yang naik, dan itu pun hanya 7,3 persen. Fraksi varietas tidak menjadi lebih akurat; ia justru tergerus.

Penyebabnya terlihat ketika fraksi kelas baru diperiksa. Kelas **tanah menyerap fraksi 0,2552** — lebih dari seperempat seluruh campuran — dan menjadi kelas dominan pada 34,9 persen piksel. Kelas air hanya menyerap 0,0130, hampir tidak berarti. Dengan kata lain, yang benar-benar terjadi bukanlah pemisahan yang lebih baik, melainkan munculnya **penampung sisa**. Endmember tanah dari statistik citra berperan sebagai kelas yang menelan seluruh bagian piksel yang tidak dapat dijelaskan oleh endmember padi — termasuk bagian yang sesungguhnya berasal dari padi.

Sesuai dugaan, cakupan hull memang membaik dan RMSE memang turun: dari 166,0 persen menjadi 118,6 persen. Perlu ditegaskan bahwa 166,0 persen di sini adalah RMSE pada komposit jendela lama yang telah dirata-ratakan, berbeda dari 179,4 persen pada tabel §12.2 yang dihitung pada penguraian penuh; karena itu angka 118,6 persen hanya boleh dibandingkan dengan 166,0 persen, bukan dengan 179,4 persen. Tetapi akurasi pemisahan padi turun dari 91,1 persen menjadi **88,3 persen**, dan IR64 yang pada lima kelas dikenali benar 59,7 persen kini turun menjadi 53,8 persen. Jadi pendekatan kedua mengulangi pola yang sama seperti pendekatan pertama: gejala membaik, hasil memburuk.

Pelajaran di sini lebih halus daripada pada penskalaan. Kelas tambahan memang menaikkan cakupan hull, tetapi tidak menambah informasi yang benar. Sebuah kelas yang tidak punya dasar fisik untuk hadir di sawah — seperti tanah yang endmembersnya diambil dari statistik citra, bukan dari kanopi yang diukur secara terkendali — akan berperan

sebagai saluran pembuangan bagi sisa model. Hull menjadi terisi bukan karena piksel benar-benar dapat dijelaskan, melainkan karena ada kelas yang bersedia menampung apa saja. Itulah alasan mengapa kelas non-padi tidak boleh ditambahkan lagi.

12.5 Pendekatan ketiga: koreksi per kanal

Pendekatan ketiga lahir dari kritik yang sah terhadap pendekatan pertama. Penskalaan skalar mengalikan seluruh spektrum dengan satu angka, padahal kenyataannya setiap kanal tidak menyusut dengan cara yang sama. Bila penyusutan antar-kanal tidak seragam, maka yang lebih tepat adalah mengoreksi setiap kanal dengan faktornya sendiri — sebuah vektor koreksi, bukan satu skalar.

Kritik ini benar; data membuktikannya. Ketika penyusutan per kanal diukur terhadap endmember Mekongga, rasionya tidak seragam sama sekali. Nilainya: B1 sebesar 4,640, B2 1,243, B3 0,790, B4 1,322, B5 0,675, B6 0,571, B7 0,561, B8 0,540, dan B9 0,554; rentangnya membentang dari 0,54 sampai 4,64 — selisih hampir sembilan kali. Satu skalar memang tidak dapat mewakili penyusutan yang sedemikian tidak seragam.

Vektor koreksi yang akhirnya dipakai adalah $[0,366 \cdot 0,444 \cdot 0,479 \cdot 0,596 \cdot 0,548 \cdot 0,548 \cdot 0,553 \cdot 0,534 \cdot 0,548]$. Dengan vektor ini, setiap kanal disesuaikan secara terpisah sehingga bentuk spektrum endmember bergeser menuju bentuk spektrum piksel.

Secara teori, koreksi per kanal seharusnya mengungguli penskalaan skalar, karena ia mengubah **bentuk** spektrum, bukan sekadar skalanya. Pada Bab 3 sudah dijelaskan bahwa FCLS tidak invarian terhadap perubahan bentuk. Jadi kali ini fraksi memang akan berubah, dan ada harapan bahwa perubahan itu memperbaiki hasil.

Hasilnya membantah harapan itu. RMSE turun dari 179,4 persen menjadi **46,2 persen**, dan cakupan hull naik menjadi 12,7 persen. Tetapi akurasi pemisahan hanya mencapai **81,6 persen** — lebih buruk daripada 91,1 persen endmember apa adanya, dan hanya sedikit lebih baik daripada penskalaan skalar 79,5 persen.

Yang lebih merusak lagi, koreksi per kanal **mengubah urutan dominasi varietas**. Inilah bukti paling telak bahwa pendekatan ini bukan memperbaiki, melainkan mengacaukan.

Varietas	A. apa adanya	D. vektor
Ciherang	0,0711	0,1321
IR64	0,0468	0,0481
Inpari32	0,0879	0,3416
Inpari32_WBC	0,2397	0,2180
Mekongga	0,5546	0,2603

Pada endmember apa adanya, urutan dominasi adalah **Mekongga > Inpari32_WBC > Inpari32**, dengan Mekongga memimpin jauh pada fraksi 0,5546. Setelah koreksi per kanal, urutan itu terbalik menjadi **Inpari32 > Mekongga > Inpari32_WBC**: fraksi Inpari32 melonjak dari 0,0879 menjadi 0,3416, sementara fraksi Mekongga merosot dari 0,5546 menjadi 0,2603.

Pergeseran sebesar itu bukan penyempurnaan hasil; itu pembalikan kesimpulan. Uji yang sama dijalankan pada sensor keempat (WorldView-2) dan hasilnya membuka satu syarat yang tidak terlihat di sini; syarat itu dibahas pada bagian 13.6.2. Dominasi Mekongga pada endmember apa adanya terbukti konsisten di belasan percobaan: 15 kombinasi Speclib, 5 sensor, 2 masker, 2 jendela tanggal, dan 4 skema endmember. Akurasi pemisahan Mekongga sendiri adalah 100 persen. Ketika sebuah koreksi membalik temuan yang sudah kokoh, koreksi itu bukan memperbaiki data, melainkan menambahkan distorsi.

Mengapa koreksi per kanal gagal meskipun secara teori lebih benar daripada penskalaan? Sebab utamanya sama seperti pada penskalaan: mengecilkan endmember memperburuk rasio sinyal terhadap derau. Ukuran pergeseran itu terlihat pada penyusutan jarak antar-varietas.

Pasangan	A. asli	D. vektor	Perubahan
Ciherang–IR64	0,1222	0,0649	–46,9%
Ciherang–Mekongga	0,2731	0,1171	–57,1%
IR64–Mekongga	0,2140	0,0855	–60,0%

Jarak antar-varietas menyusut 45 sampai 60 persen. Padahal justru jarak inilah yang membedakan varietas. Setelah penyusutan sebesar itu, perbedaan yang tersisa menjadi sebanding dengan derau citra, dan pemisahan yang tadinya dapat diandalkan menjadi rapuh. Perlu dicatat bahwa rasio singular (singular-value ratio) hampir tidak berubah: dari 410,8 menjadi 411,8; artinya masalahnya bukan geometri simpleks (simplex) yang menjadi gepeng — geometrinya tetap sama. Yang berubah adalah **skala absolut perbedaan** dibandingkan dengan derau, dan itulah yang merusak akurasi.

12.6 Pendekatan keempat: ekstraksi piksel murni (PPI)

Pendekatan keempat berbeda sifatnya dari ketiga pendekatan sebelumnya. Bila ketiga pendekatan pertama berusaha menyesuaikan endmember SpecLib supaya cocok dengan citra, pendekatan keempat meninggalkan SpecLib sama sekali dan menurunkan endmember dari citra itu sendiri. Metodenya adalah **Pixel Purity Index (PPI)**, yang telah diperkenalkan pada Bab 4: garis-garis acak dilemparkan melewati awan piksel, dan piksel yang paling sering muncul di ujung garis dianggap paling murni.

Rancangan ujinya dibuat ketat untuk menghindari pemanis hasil. Ekstraksi dilakukan hanya pada **separuh barat** area kajian, yang memuat 1.367.326 piksel. Endmember hasil ekstraksi itu kemudian diuji pada **separuh timur** yang tidak dipakai untuk ekstraksi, memuat 626.590 piksel. Pemisahan wilayah ini penting: bila endmember yang diekstraksi dari satu wilayah berhasil menguraikan wilayah lain, maka endmember itu menangkap sifat umum, bukan kebetulan setempat.

Prosedurnya berjalan mulus secara teknis. Dari 150.000 subsampel dan 2.000 skewer, PPI menghasilkan 322 piksel murni. Piksel-piksel itu dikelompokkan dengan k-means menjadi 5 klaster, dengan ukuran klaster [642, 184, 456, **19**, 699]; perhatikan klaster terkecil: hanya 19 piksel. Sebuah "varietas" yang diwakili 19 piksel dari jutaan adalah tanda pertama bahwa jumlah klaster lima tidak didukung data.

Hasil pencocokan endmember PPI dengan endmember SpecLib memperlihatkan masalah yang sama.

EM PPI	cocok dengan	SAM	skala	korelasi
EM0	Inpari32	11,2°	0,426	0,9809
EM1	Inpari32_WB C	11,4°	0,100	0,9802
EM2	Mekongga	2,8°	0,552	0,9988
EM3	Inpari32_WB C	14,3°	0,517	0,9690
EM4	Inpari32	4,0°	0,543	0,9976

Endmember EM2 dari PPI cocok hampir sempurna dengan Mekongga Speclib — hanya 2,8 derajat sudut spektral, dengan korelasi 0,9988. Ini sekaligus menjadi konfirmasi independen bahwa endmember Speclib memang benar. Tetapi perhatikan dua hal lain. **Pertama**, dua endmember berbeda — EM0 dan EM4 — sama-sama cocok dengan Inpari32. **Kedua**, dua endmember lain — EM1 dan EM3 — sama-sama cocok dengan Inpari32_WBC. Jadi dari lima endmember yang ditemukan PPI, hanya **tiga varietas berbeda** yang sebenarnya terwakili: Mekongga, Inpari32, dan Inpari32_WBC. Ciherang dan IR64 tidak ditemukan sama sekali.

Ini bukan kekeliruan kecil. PPI diberi tugas menemukan lima kelas, dan secara mekanis ia mengembalikan lima kluster — tetapi isinya hanya tiga kelas. Empat dari lima endmember hanyalah variasi dari dua kelas yang sama; dengan kata lain, PPI menemukan lima **arah spektral** dalam data, bukan lima **varietas**. Karena Ciherang dan IR64 tidak muncul, metode ini tidak mungkin memisahkan keduanya.

Perhatikan juga kolom skala. Faktor skala antara endmember PPI dan endmember Speclib sangat tidak seragam: EM1 hanya 0,100, sedangkan EM2 sebesar 0,552. Piksel yang dianggap "murni" oleh PPI ternyata masih jauh lebih gelap daripada kanopi padi murni. Ini konsisten dengan temuan Bab 11 bahwa piksel murni pada resolusi 30 meter tetap merupakan campuran.

Meskipun demikian, PPI berhasil pada dua ukuran yang selama ini dianggap penting. Cakupan hull melonjak dari **0 persen menjadi 51,6 persen** — jauh lebih tinggi daripada penskalaan skalar (16,8 persen) maupun koreksi per kanal (12,7 persen). RMSE turun dari 179,4 persen

menjadi **23,0 persen** — yang terendah di antara semua pendekatan. Pada kedua ukuran itu, PPI adalah pemenang mutlak.

Tetapi hasil yang sesungguhnya hancur. **Piksel ekstrem (extreme pixel) naik lebih dari dua kali**, dari 8,9 persen menjadi **17,4 persen**. Piksel ekstrem adalah piksel yang solusinya terdorong ke sudut simpleks — fraksi satu kelas mendekati satu, kelas lain mendekati nol. Naiknya ekstrem ke 17,4 persen berarti hampir seperlima piksel padi menghasilkan solusi yang secara praktis tidak bermakna. Fraksinya pun kacau: karena dua klaster sama-sama cocok ke Inpari32, kelas itu menerima bagian yang seharusnya menjadi milik kelas lain. Akurasi pun tidak dapat dilaporkan sebagai satu angka tunggal.

Mengapa PPI gagal meskipun ia menemukan endmember yang benar? Karena pada resolusi 30 meter, tidak ada piksel yang benar-benar murni. Piksel yang paling ekstrem di dalam citra tetap merupakan campuran padi, air, dan tanah; ketika PPI mencari arah variasi terbesar, yang ia temukan bukan varietas, melainkan campuran variasi fase tumbuh, kondisi tanaman, dan keadaan permukaan. Endmember Mekongga kebetulan cocok karena dominasi Mekongga di area itu sangat kuat, tetapi kelas-kelas lain tenggelam dalam variasi yang tidak berkaitan dengan varietas.

12.7 Pola yang menghubungkan keempatnya

Empat pendekatan, empat jalur berbeda, dan satu pola yang sama. Pola itu paling jelas terlihat ketika keempatnya disandingkan.

Pendekatan	RMSE	Cakupan hull	Piksel ekstrem	Hasil
Speclib apa adanya	179,4%	0%	8,9%	terbaik
Penskalaan skalar k=0,40	31,7%	16,8%	3,8%	lebih buruk
Koreksi per kanal (vektor)	46,2%	12,7%	3,7%	lebih buruk
Ekstraksi piksel murni (PPI)	23,0%	51,6%	17,4%	lebih buruk

Bacalah tabel ini sebagai satu kalimat: **setiap kali RMSE turun atau cakupan hull naik, hasilnya justru memburuk**. Tidak ada satu pun pengecualian. Setiap perbaikan pada ukuran diagnostik selalu disertai kemunduran pada hasil yang sesungguhnya. Ini bukan kebetulan statistik, bukan pula akibat kesalahan uji; ini sifat masalahnya.

Mengapa demikian? Karena RMSE dan cakupan hull mengukur seberapa cocok endmember dengan citra secara **keseluruhan**, sedangkan yang kita butuhkan adalah seberapa baik **kelas-kelas berbeda dipisahkan**. Kedua hal itu tidak searah, dan dalam kasus ini justru berlawanan arah. Endmember dapat dibuat lebih cocok dengan citra dengan cara diperkecil — dan itu otomatis menurunkan RMSE, karena selisih antara spektrum piksel dan endmember yang lebih kecil menjadi lebih kecil. Tetapi memperkecil endmember sekaligus mengecilkan perbedaan antar-kelas, sehingga pemisahan yang tadinya mungkin menjadi tidak mungkin. Hull dapat diisi dengan menambahkan kelas penampung (catch-all class) atau dengan mencari endmember dari citra, tetapi keduanya memasukkan variasi yang bukan varietas ke dalam model, sehingga fraksi varietas justru terdistorsi.

Perhatikan juga kolom piksel ekstrem, karena di sanalah pola itu paling jelas terlihat. Endmember apa adanya menghasilkan 8,9 persen piksel ekstrem — angka yang sudah tidak ideal; penskalaan dan koreksi per kanal justru menurunkannya menjadi 3,8 dan 3,7 persen, tetapi akurasi juga turun. Turunnya ekstrem di sini bukan tanda perbaikan, melainkan efek samping dari endmember yang diperkecil. Sementara PPI, yang cakupan hull-nya paling tinggi dan RMSE-nya paling rendah, justru meledakkan ekstrem menjadi 17,4 persen. Naiknya ekstrem adalah tanda paling dapat dipercaya bahwa solusi sedang terdorong ke batas — bahwa endmember tidak mencakup citra, dan model dipaksa mengarang jawaban. Bab 13 akan mengembangkan gagasan ini menjadi kerangka penilaian yang benar.

12.8 Yang perlu diingat dari bab ini

Pertama, titik tolak endmember SpecLib apa adanya adalah yang terbaik: akurasi pemisahan 91,1 persen. Angka RMSE-nya memang paling buruk, tetapi RMSE bukan ukuran keberhasilan pemisahan.

Kedua, penskalaan skalar $k=0,40$ menaikkan cakupan hull menjadi 16,8 persen dan menurunkan RMSE menjadi 31,7 persen, tetapi menurunkan akurasi menjadi 79,5 persen; penyebabnya adalah invarian skala (scale invariance) FCLS dan memburuknya rasio sinyal terhadap derau.

Ketiga, kelas non-padi yang ditambahkan menurunkan RMSE menjadi 118,6 persen tetapi menurunkan akurasi menjadi 88,3 persen. Kelas tanah berfungsi sebagai penampung sisa dengan fraksi 0,2552, bukan sebagai pemisah yang sah.

Keempat, koreksi per kanal menurunkan RMSE menjadi 46,2 persen tetapi menurunkan akurasi menjadi 81,6 persen, dan yang lebih merusak, ia **membalik urutan dominasi** varietas dari Mekongga-dominan menjadi Inpari32-dominan.

Kelima, ekstraksi piksel murni dengan PPI adalah yang paling menyesatkan. Cakupan hull naik dari 0 menjadi 51,6 persen dan RMSE turun menjadi 23,0 persen, tetapi hanya tiga varietas berbeda yang ditemukan dari lima klaster; piksel ekstrem pun naik dua kali menjadi 17,4 persen.

Keenam, dan yang paling penting: tidak ada satu pun pengecualian dari pola bahwa perbaikan RMSE dan cakupan hull selalu disertai kemunduran hasil. Keempat jalan ini sudah tertutup. Jangan diulang.

BAB XIII METRIK YANG MENYESATKAN

13.1 Dua angka yang berlawanan arah

Bab 12 menyajikan sebuah tabel, dan di dalam tabel itu tersembunyi sebuah pertanyaan yang belum dijawab. Endmember Speclib apa adanya memiliki RMSE 179,4 persen dan akurasi 91,1 persen. Penskalaan skalar $k=0,40$ memiliki RMSE 31,7 persen dan akurasi 79,5 persen; bila kedua baris itu disandingkan pada kolom RMSE, penskalaan terlihat **5,7 kali lebih baik**. Angka 31,7 jauh lebih kecil daripada 179,4, dan dalam ukuran apa pun itu tampak seperti perbaikan besar. Bila disandingkan pada kolom akurasi, penskalaan justru **11,6 poin lebih buruk** — 79,5 persen melawan 91,1 persen.

Ambil contoh yang paling ekstrem. Endmember apa adanya memiliki RMSE 179,4 persen. Ekstraksi piksel murni memiliki RMSE 23,0 persen. Keduanya berbeda hampir **delapan kali lipat** — 179,4 dibagi 23,0 sama dengan 7,8. Sekarang bandingkan akurasinya. Endmember apa adanya mencapai 91,1 persen. PPI menghasilkan fraksi kacau yang akurasinya tidak dapat dilaporkan sebagai satu angka. Yang dapat dilaporkan adalah bahwa 17,4 persen pikselnya ekstrem, lebih dari dua kali lipat 8,9 persen pada endmember apa adanya. Jadi sebuah pendekatan yang menurunkan RMSE hampir delapan kali lipat justru menghasilkan pemisahan yang jauh lebih buruk.

Inilah inti bab ini. RMSE turun hampir enam kali sambil akurasi turun hampir dua belas poin persen. Kedua angka itu bergerak berlawanan arah, dan siapa pun yang memakai RMSE untuk memilih model akan memilih model yang salah. Bab ini menjelaskan **mengapa** hal itu terjadi — bukan sekadar melaporkan **bahwa** hal itu terjadi — dan kemudian menyusun kerangka penilaian yang benar untuk menggantikannya.

13.2 Mengapa RMSE turun ketika endmember diperkecil

Mekanisme yang pertama, dan yang paling mendasar, adalah invarian skala FCLS yang telah dibahas pada Bab 3; perlu diuraikan ulang di sini karena dialah yang menjelaskan sebagian besar kekacauan dalam tabel Bab 12.

FCLS mencari fraksi f yang meminimumkan galat $\|x - Ef\|^2$ dengan kendala $\sum f_i = 1$ dan $f_i \geq 0$ [2,12]. Sekarang andaikan seluruh

matriks endmember E dikalikan dengan konstanta k yang lebih kecil dari satu, sehingga menjadi kE . Karena kendala jumlah-satu tetap berlaku, solusi optimal f untuk masalah yang baru **sama persis** dengan solusi untuk masalah yang lama. Fraksi tidak bergerak sedikit pun. Yang berubah hanyalah nilai galat: selisih antara x dan kEf menjadi lebih kecil, karena kEf mendekati nol dan x juga bernilai kecil. Maka RMSE pun turun — tanpa satu pun perubahan pada hasil yang sebenarnya dicari.

Inilah mengapa penskalaan skalar $k=0,40$ dapat menurunkan RMSE dari 179,4 persen menjadi 31,7 persen. Ia tidak memperbaiki apa pun. Ia hanya memindahkan titik acuan galat. Fraksi yang timbul dari penskalaan identik dengan fraksi endmember apa adanya — sampai di situ, penskalaan bahkan tidak merugikan, ia hanya tidak berguna.

Tetapi penskalaan memang merugikan, dan inilah mekanisme yang kedua. Mengecilkan endmember tanpa mengecilkan derau citra memperburuk rasio antara sinyal dan derau. Sinyal yang dimaksud di sini adalah **jarak antar-varietas** — perbedaan spektral yang membedakan Ciherang dari IR64, Mekongga dari Inpari32. Ketika endmember diperkecil dengan vektor koreksi, jarak itu menyusut drastis: Ciherang–IR64 dari 0,1222 menjadi 0,0649, Ciherang–Mekongga dari 0,2731 menjadi 0,1171, dan IR64–Mekongga dari 0,2140 menjadi 0,0855. Penyusutannya 45 sampai 60 persen.

Derau citra tidak ikut menyusut. Maka perbedaan antar-varietas yang tadinya beberapa kali lebih besar daripada derau kini menjadi sebanding dengan derau. Setelah penyusutan sebesar itu, tidak ada algoritme yang dapat memisahkan kelas-kelas yang perbedaannya sudah tenggelam. Akurasi turun — dari 91,1 persen menjadi 79,5 persen pada penskalaan, dan menjadi 81,6 persen pada koreksi per kanal. Perhatikan bahwa pada koreksi per kanal, rasio singular hampir tidak berubah (410,8 menjadi 411,8); geometri simpleksnya tetap sama. Yang berubah hanyalah skala perbedaan dibandingkan derau.

Jadi RMSE dapat turun melalui dua jalan, dan keduanya menyesatkan. Jalan pertama adalah mengecilkan endmember, yang menurunkan galat secara aritmetis tanpa mengubah fraksi. Jalan kedua adalah menambahkan kelas, yang menurunkan galat karena ada kelas penampung yang menelan sisa. Kelas tanah pada uji Bab 12 menyerap

fraksi 0,2552 dan menjadi dominan pada 34,9 persen piksel. Kedua-duanya membuat RMSE turun, dan kedua-duanya membuat hasil memburuk.

Mekanisme penurunan RMSE oleh penskalaan dapat digambarkan dengan angka yang paling kasar sekalipun. Bayangkan sebuah piksel dengan nilai reflektansi inframerah dekat 0,3, sementara endmember yang tersedia bernilai 0,6. Galat rekonstruksinya sebesar 0,3. Sekarang endmember itu dikalikan 0,5 sehingga menjadi 0,3. Galatnya menjadi nol — sempurna. Tetapi fraksi yang dihasilkan tidak berubah sedikit pun, karena kendala jumlah-satu tetap memaksa fraksi yang sama seperti sebelumnya; yang terjadi hanyalah endmember digeser turun sampai kebetulan bertemu nilai piksel, dan pertemuan itu dicatat sebagai perbaikan galat. Bila operasi itu diulang untuk seluruh citra, RMSE akan turun secara sistematis tanpa satu pun piksel menjadi lebih teruraikan. Inilah sebabnya angka RMSE yang turun tajam dari 179,4 persen menjadi 31,7 persen pada penskalaan $k=0,40$ harus dibaca dengan sangat hati-hati: sebagian besar penurunan itu berasal dari pergeseran titik acuan, bukan dari pemisahan yang membaik.

Yang lebih berbahaya lagi, penurunan ini tidak punya batas; penskalaan dapat diteruskan sampai endmember mendekati nol, dan RMSE akan terus membaik sampai galat rekonstruksinya mendekati nol seluruhnya. Sebuah algoritme optimisasi yang tidak mengenal batas ini akan dengan senang hati memilih endmember yang paling kecil, karena itulah yang meminimumkan galat. Itulah sebabnya RMSE tidak dapat menjadi fungsi tujuan dalam memilih endmember. Ia bukan sekadar kurang tepat; ia aktif mengarahkan ke pilihan yang salah.

Yang membuat RMSE menjadi ukuran yang benar-benar berbahaya adalah bahwa ia **selalu** turun ketika endmember diperkecil atau kelas ditambah. Tidak ada batas di mana penurunan RMSE berhenti menandakan perbaikan. Seseorang dapat terus memperkecil endmember, terus melihat RMSE membaik, dan terus menurunkan akurasi, tanpa pernah menyadari bahwa ia sedang merusak hasil. RMSE tidak memiliki mekanisme internal untuk memperingatkan bahwa sesuatu sudah salah. Karena itulah ia tidak boleh menjadi dasar memilih model.

13.3 Mengapa cakupan hull bukan sasaran

Ukuran kedua yang menyesatkan adalah **cakupan hull** — persentase piksel yang berada di dalam convex hull endmember. Pada Bab 2, ukuran ini diperkenalkan sebagai diagnostik, dan pada Bab 11 ia menjadi pusat investigasi panjang. Di sini perlu ditegaskan mengapa ia tidak boleh dijadikan sasaran.

Kenyataannya di area kajian sudah terukur dengan tegas. Seluruh piksel padi berada di luar convex hull endmember SpecLib. Pada bidang merah–inframerah dekat, red-edge1–inframerah dekat, dan red-edge2–inframerah dekat, cakupan hull adalah 0,0 persen pada ketiganya. Rata-rata hanya 2,4 dari 9 kanal piksel padi yang nilainya jatuh di dalam rentang endmember. Sebagaimana terbukti pada Bab 6, hull juga kosong di data Landsat 9 — 0,0 persen pada ketiga bidang kanal yang diuji. Jadi kondisi ini bukan akibat sensor atau pemrosesan, melainkan universal.

Akar masalahnya terukur dan bukan cacat yang perlu diperbaiki. Endmember SpecLib memiliki nilai inframerah dekat 0,5927 sampai 0,8464. Citra padi hanya mencapai persentil 99 sebesar 0,4444, dan dari 1.994.687 piksel padi hanya **177 piksel** — 0,009 persen — yang mencapai 0,5927. Bahkan rata-rata piksel di atas persentil 99 hanya 0,4730. Perbedaan ini timbul karena endmember diukur dari kanopi padi saja, sedangkan piksel Sentinel-2 selalu memuat tanah, air, dan pematang. Inilah efek pencampuran resolusi, dan ia tidak dapat dihilangkan dengan mengubah endmember.

Karena hull kosong adalah **kenyataan fisik**, mengisi hull berarti melawan kenyataan. Itulah yang dilakukan keempat pendekatan pada Bab 12, dan itulah mengapa keempatnya gagal. Penskalaan mengisi hull sampai 16,8 persen, koreksi per kanal sampai 12,7 persen, dan PPI sampai 51,6 persen. Setiap kenaikan cakupan hull diperoleh dengan cara memaksa endmember agar cocok dengan citra — baik dengan memperkecilnya maupun dengan menggantinya dengan endmember dari citra. Dan setiap kali itu dilakukan, akurasi turun. Perlu diingat bahwa menurut definisi convex hull, sebuah piksel yang merupakan campuran sah dari endmember pasti berada di dalam hull [3]. Maka hull yang kosong hanya dapat berarti bahwa endmember dan piksel memang bukan benda yang sama — bukan bahwa endmember salah.

Perhatikan angka PPI dengan saksama, karena ia adalah bukti paling telak. PPI menaikkan cakupan hull dari nol menjadi **51,6 persen** — lebih dari separuh piksel kini berada di dalam hull. Tidak ada satu pun pendekatan lain yang sedekat itu untuk "menyelesaikan" masalah hull. Tetapi justru PPI yang paling merusak fraksinya, menemukan hanya tiga varietas berbeda dari lima klaster, dan meledakkan piksel ekstrem menjadi 17,4 persen. Jika cakupan hull adalah sasaran, PPI adalah pemenang mutlak; jika hasil pemisahan yang menjadi sasaran, PPI adalah yang terburuk. Itu sebabnya cakupan hull harus diperlakukan sebagai **diagnostik**, bukan sasaran: ia memberi tahu bahwa ada perbedaan mendasar antara endmember dan citra, dan tugas kita adalah memahami perbedaan itu, bukan menghapusnya.

13.4 Piksel ekstrem sebagai penanda yang andal

Di antara semua ukuran yang dibahas, ada satu yang perilakunya paling dapat dipercaya: **persentase piksel ekstrem**; piksel ekstrem adalah piksel yang solusinya terdorong ke sudut simpleks — fraksi satu kelas mendekati satu, kelas lain mendekati nol. Ini terjadi ketika algoritme menghadapi piksel di luar hull dan, karena tidak ada solusi sah di dalam ruang solusi, memilih titik terdekat pada batas. Solusi seperti ini secara praktis tidak bermakna: ia bukan ukuran yang sah, melainkan kompromi aritmetis.

Mengapa piksel ekstrem lebih dapat diandalkan daripada RMSE dan cakupan hull? Karena ia mengukur sesuatu yang tidak dapat dimanipulasi oleh penskalaan. Mengecilkan endmember menurunkan RMSE tanpa mengubah fraksi, tetapi ia tidak dapat menyembunyikan fakta bahwa solusi masih terdorong ke batas. Menambahkan kelas penampung mengisi hull, tetapi kelas penampung itu justru menciptakan solusi sudut baru. Piksel ekstrem mengukur langsung seberapa sering model dipaksa mengarah jawaban, dan itulah yang ingin kita ketahui.

Tetapi indikator ini memiliki satu nuansa yang penting, dan nuansa itu harus dipahami dengan benar. Pada tabel Bab 12, endmember apa adanya memiliki 8,9 persen piksel ekstrem, sementara penskalaan skalar dan koreksi per kanal justru menurunkannya menjadi 3,8 dan 3,7 persen. Bila dibaca sepintas, ini tampak seperti perbaikan — seolah penskalaan dan koreksi berhasil mengurangi solusi sudut. Padahal tidak. Akurasi kedua pendekatan itu justru lebih buruk (79,5 dan 81,6 persen). Jadi turunnya

ekstrem di sini bukan tanda perbaikan, melainkan efek samping dari endmember yang diperkecil. Ketika seluruh endmember dikecilkan, solusi tidak lagi terdorong ke sudut dengan cara yang sama, karena galatnya tersebar merata. Ekstrem turun, tetapi pemisahan juga rusak.

Sebaliknya, pada PPI, ekstrem **naik lebih dari dua kali** — dari 8,9 persen menjadi 17,4 persen — dan kenaikan itu benar-benar menandakan kerusakan. PPI mengganti endmember dengan versi dari citra, yang lebih cocok secara keseluruhan, sehingga cakupan hull melonjak. Tetapi endmember hasil ekstraksi itu tidak mewakili kelas varietas yang berbeda; ia mewakili arah spektral yang berbeda, dan hanya tiga varietas yang benar-benar terwakili. Akibatnya model terus dipaksa memilih antara kelas-kelas yang tidak benar-benar terpisah, dan solusinya terdorong ke sudut pada 17,4 persen piksel.

Pelajaran yang dapat diambil: **piksel ekstrem harus dibaca bersama akurasi, bukan sendirian**. Ketika ekstrem naik bersamaan dengan memburuknya fraksi, itu tanda yang jelas bahwa endmember tidak mencakup citra. Ketika ekstrem turun, itu tidak otomatis berarti perbaikan — harus diperiksa apakah akurasinya ikut membaik. Yang membuat ekstrem berguna bukanlah arah perubahannya, melainkan fakta bahwa ia tidak dapat diturunkan dengan cara-cara aritmetis yang menyesatkan RMSE. Ia tetap menjadi indikator yang paling dapat diandalkan di antara ukuran-ukuran yang tersedia, dengan catatan bahwa ia harus ditafsirkan dalam konteks.

13.5 Fraksi dan urutan dominasi

Ada satu lagi jenis bukti yang lebih kuat daripada metrik angka mana pun, dan itu adalah **konsistensi urutan dominasi**. Endmember apa adanya memberi urutan Mekongga > Inpari32_WBC > Inpari32, dengan Mekongga pada fraksi 0,5546. Urutan ini tidak muncul sekali; ia konsisten di belasan percobaan — 15 kombinasi Speclib, 5 sensor, 2 masker, 2 jendela tanggal, dan 4 skema endmember. Akurasi pemisahan Mekongga sendiri adalah 100 persen.

Koreksi per kanal membalik urutan itu menjadi Inpari32 > Mekongga > Inpari32_WBC, dengan Inpari32 melonjak dari 0,0879 menjadi 0,3416 dan Mekongga merosot dari 0,5546 menjadi 0,2603. Pembalikan seperti ini adalah tanda bahaya yang lebih kuat daripada angka RMSE mana pun.

Sebuah temuan yang telah terbukti kokoh di belasan percobaan tidak boleh terbalik oleh satu perlakuan; bila terbalik, maka perlakuan itulah yang salah.

Karena itu, dalam menilai apakah sebuah pengolahan berhasil, langkah pertama yang paling murah adalah memeriksa apakah urutan dominasi tetap sama. Bila berubah, pengolahan itu telah mengubah kesimpulan, dan perubahan kesimpulan harus dipertanggungjawabkan dengan bukti yang sangat kuat — bukan dengan penurunan RMSE. Pada kasus ini, tidak ada bukti semacam itu, sehingga koreksi per kanal ditolak bukan terutama karena akurasinya lebih rendah, tetapi karena ia membalik urutan dominasi. Perlu dicatat bahwa uji ini memiliki satu syarat yang menentukan sahnya, dan syarat itu dibahas pada bagian 13.6.2.

Perlu ditegaskan mengapa urutan dominasi lebih kuat daripada sekadar angka akurasi. Akurasi mengukur performa pada himpunan piksel uji yang dibuat secara sintetis — campuran acak dengan derau yang diketahui — sehingga ia mengukur kemampuan algoritme dalam kondisi terkendali. Urutan dominasi, sebaliknya, mengukur sifat data yang sesungguhnya. Ia muncul dari fraksi yang dihitung pada jutaan piksel padi nyata, dan ia telah diperiksa ulang di bawah belasan kondisi berbeda. Ketika sebuah temuan bertahan di 15 kombinasi Speclib, 5 sensor, 2 masker, 2 jendela tanggal, dan 4 skema endmember, maka temuan itu bukan artefak satu percobaan. Ia adalah sifat nyata dari lanskap sawah Indramayu, tempat varietas Mekongga memang mendominasi. Karena itu membalik urutan ini berarti mengubah gambaran tentang lanskap itu sendiri, dan perubahan sebesar itu tidak boleh terjadi sebagai efek samping dari sebuah koreksi teknis.

Di sinilah letak perbedaan penting antara menilai alat dan menilai hasil. Alat — FCLS, matriks kekeliruan, derau sintetis — dinilai dengan angka akurasi. Hasil — peta varietas yang dilaporkan kepada pengguna — dinilai dengan konsistensi dan kesesuaian terhadap kenyataan lapangan. Endmember apa adanya lulus kedua penilaian itu: akurasinya 91,1 persen dan urutan dominasinya stabil. Ketiga pendekatan perbaikan gagal setidaknya pada salah satunya, dan koreksi per kanal gagal pada keduanya sekaligus karena akurasinya 81,6 persen dan urutannya terbalik.

13.6 Kerangka penilaian yang benar

Dari seluruh pembahasan di atas, sebuah kerangka penilaian dapat disusun. Kerangka ini menggantikan kebiasaan lama yang mengandalkan RMSE dan cakupan hull, dan menggantikannya dengan ukuran-ukuran yang searah dengan tujuan sesungguhnya.

Pertama: akurasi pemisahan, bukan galat rekonstruksi. Ukuran utama untuk menilai kualitas pemisahan varietas adalah akurasi dari matriks kekeliruan piksel murni. Ambangnya jelas: di atas 85 persen layak dilanjutkan, di bawah itu hentikan. Endmember SpecLib apa adanya mencapai 91,1 persen dan karena itu layak. Ketiga pendekatan perbaikan pada Bab 12 berada di bawah 85 persen atau menghasilkan fraksi yang kacau, dan karena itu ditolak. Ukuran ini mengukur hal yang benar — seberapa baik kelas-kelas berbeda dipisahkan — dan tidak dapat diturunkan dengan mengecilkan endmember. Perlu dicatat bahwa prinsip penilaian dengan matriks kekeliruan ini adalah praktik baku dalam penginderaan jauh. Penggunaannya di sini mengikuti logika yang sama seperti yang dipakai untuk menilai klasifikasi tutupan lahan [6,7].

Kedua: konsistensi urutan dominasi. Setiap pengolahan harus menjaga urutan dominasi varietas. Bila urutan berubah, pengolahan itu dicurigai sampai terbukti sebaliknya. Ini adalah uji yang murah dan menangkap kesalahan yang tidak tertangkap akurasi, sebagaimana terlihat pada koreksi per kanal.

Ketiga: piksel ekstrem sebagai indikator, bukan sasaran. Persentase piksel ekstrem harus dilaporkan dan dipantau. Ambang (threshold) praktis: di bawah 1 persen baik, dan kenaikan yang signifikan menandakan solusi terdorong ke batas. Nilai harus selalu ditafsirkan bersama akurasi, karena ekstrem dapat turun karena alasan yang salah.

Keempat: metrik masker yang tepat. Untuk menilai masker padi, F1 menyesatkan pada kelas tidak seimbang. Masker yang menjawab "semua padi" memperoleh F1 70,9 persen, hampir menyamai masker sungguhan 71,8 persen. Ukuran yang benar adalah MCC dan kappa, yang memperhitungkan keempat sel matriks kekeliruan sekaligus. Ambangnya: di atas 0,4 sedang, di atas 0,6 kuat. Masker fenologi MODIS mencapai MCC 0,436 dan gabungan ATAU mencapai 0,491 — keduanya pada kelas sedang, dan itu harus dilaporkan apa adanya.

Kelima: RMSE dan cakupan hull dilaporkan, tetapi tidak dipakai untuk memilih. Keduanya tetap berguna sebagai diagnostik. RMSE memberi tahu seberapa besar galat rekonstruksi, dan cakupan hull memberi tahu seberapa jauh endmember dari citra. Tetapi keduanya tidak boleh dipakai untuk memutuskan model mana yang lebih baik, karena keduanya dapat diperbaiki dengan cara-cara yang merusak hasil. Melaporkan keduanya secara terbuka justru penting — agar pembaca dapat menilai sendiri — tetapi keputusan harus dibuat berdasarkan akurasi, konsistensi dominasi, dan piksel ekstrem.

Kerangka ini berlaku pada tingkat pemilihan endmember dan pemilihan model. Namun ia tidak boleh dipisahkan dari keputusan-keputusan hulu yang sudah dibahas pada Bab 6 sampai Bab 8. Kesalahan pada tahap itu akan membuat seluruh penilaian di hilir menjadi tidak bermakna. Pemilihan sensor menentukan apakah varietas dapat dipisahkan sama sekali: kanal red-edge yang membedakan Sentinel-2 dari Landsat adalah kanal yang paling memuat perbedaan antar-varietas [8,10]. Penentuan jendela tanggal menentukan apakah yang diuraikan adalah padi pada fase yang sama atau campuran beberapa fase sekaligus [4]. Dan penilaian masker menentukan apakah yang diuraikan benar-benar padi atau sekadar vegetasi [5]. Dengan kata lain, kerangka penilaian yang benar tidak dimulai pada tabel akurasi; ia dimulai jauh sebelum penguraian dijalankan.

Kerangka ini punya satu ciri yang menyatukannya: **semua ukuran yang dipakai bersifat searah dengan tujuan.** Akurasi pemisahan naik berarti pemisahan membaik. Konsistensi urutan dominasi terjaga berarti hasil stabil. Piksel ekstrem tetap rendah berarti solusi sah. Tidak ada satu pun dari ketiganya yang dapat diperbaiki dengan mengecilkan endmember atau menambah kelas penampung. Itulah bedanya dengan RMSE dan cakupan hull, yang keduanya dapat diperbaiki dengan cara yang merusak.

13.6.1 Uji kebermanaan: mana ukuran yang benar-benar meramalkan akurasi

Kerangka di atas disusun dari pola yang terlihat pada sejumlah setelan. Pola yang terlihat belum tentu pola yang nyata. Karena itu seluruh ukuran yang dipakai diuji kebermanaannya, dengan lima belas kombinasi reduksi dan pemetaan sebagai amatan.

Hasilnya membenarkan sebagian kerangka ini, dan mengubah satu bagiannya secara mendasar.

Ukuran yang terbukti meramalkan akurasi hanya satu: rasio singular matriks endmember. Korelasinya dengan akurasi **-0,939** dengan nilai **$p < 0,0001$** . Hubungan ini sangat kuat dan berbeda nyata dari nol: matriks endmember yang lebih "gepeng" (rasio singular besar) selalu disertai akurasi yang lebih rendah. Karena itu rasio singular bukan sekadar ukuran deskriptif yang menarik — ia adalah **penanda mutu yang sah**, dan sebaiknya diperiksa sebelum penguraian dijalankan, bukan sesudahnya.

Ukuran yang terbukti TIDAK meramalkan akurasi: RMSE. Korelasinya hanya **+0,253** dengan **$p = 0,164$** — tidak berbeda nyata dari nol. Dengan demikian pernyataan pada bagian 13.1 bukan lagi kesan yang berasal dari beberapa contoh, melainkan hasil uji: RMSE memang tidak dapat menilai mutu hasil penguraian.

Dua ukuran lain juga tidak terbukti meramalkan akurasi, dan ini perlu dikatakan terbuka karena keduanya selama ini dipakai sebagai penjelasan. Jarak spektral minimum antar-pasangan berkorelasi hanya **+0,118** ($p = 0,800$), dan jarak pasangan Ciherang-IR64 hanya **+0,147** ($p = 0,752$). Keduanya tidak nyata.

Perbedaan antara **menjelaskan** dan **meramalkan** penting di sini. Jarak spektral tetap menjelaskan **mengapa** Ciherang dan IR64 sulit dipisahkan: ruang spektrum keduanya memang bertumpuk. Tetapi jarak spektral **tidak dapat dipakai memperkirakan** seberapa baik suatu setelan akan bekerja, karena nilainya hampir tidak berubah antar setelan sementara akurasinya berubah 2,7 poin. Ukuran yang baik untuk menjelaskan belum tentu baik untuk meramalkan.

Ukuran ketiga yang perlu diperlakukan hati-hati: akurasi berpasangan. Ukuran ini memberi nilai tertinggi justru pada setelan terburuk. Setelan Q3 dengan pemetaan Gaussian Weighting memberi akurasi berpasangan **99,95 persen** padahal akurasi sesungguhnya **92,19 persen**; setelan terbaik (Median, Nearest Band) justru memberi **99,54 persen**. Korelasi peringkatnya dengan akurasi **negatif, -0,332**. Sebabnya dapat dipahami: bila endmember dipetakan secara halus, memisahkan dua kelas saja menjadi mudah bagi hampir semua setelan, sehingga ukuran itu kehilangan daya pisah. Angka 91 persen pada Bab 10 tetap sah karena konteksnya khusus — pemisahan Ciherang melawan IR64 tanpa tiga kelas

lain. Yang tidak sah adalah memakai ukuran itu sebagai **ukuran mutu umum**.

Yang bertahan. Ketahanan (robustness) terhadap derau tetap merupakan ukuran yang berguna: menaikkan derau dari 0,5 persen menjadi 2 persen menurunkan akurasi dari 97,7 persen menjadi 82,1 persen, dengan simpangan antar-ulangan tetap kecil (0,0005 sampai 0,002). Piksel ekstrem juga bertahan sebagai penanda yang andal, sebagaimana diuraikan pada bagian 13.4.

Ringkasnya, kerangka pada bagian 13.6 berubah pada satu butir. Bukan "akurasi, konsistensi dominasi, dan piksel ekstrem", melainkan **rasio singular, akurasi, konsistensi dominasi, dan piksel ekstrem** — dengan RMSE, jarak spektral, dan akurasi berpasangan **tidak** dipakai sebagai ukuran mutu. Rasio singular ditempatkan paling awal karena ia dapat diperiksa sebelum penguraian dijalankan, sehingga setelan yang tidak layak dapat dibuang lebih awal.

Batas uji ini. Jumlah amatan hanya lima belas, dan kelimanya berbagi citra yang sama sehingga tidak sepenuhnya bebas; pernyataan "tidak nyata" karena itu berarti "**pada jumlah amatan ini tidak terbukti ada hubungan**", bukan "tidak ada hubungan". Nilai p sebaiknya dibaca sebagai indikasi yang kuat, bukan keputusan akhir.

13.6.2 Batas uji urutan dominasi: kapan ia sah dipakai

Konsistensi urutan dominasi adalah uji yang murah, dan pada Bab 12 uji itu sudah cukup untuk menolak koreksi per kanal. Ketika uji yang sama dijalankan pada sensor keempat, muncul satu syarat yang belum pernah terlihat — dan syarat itulah yang menentukan apakah uji tersebut boleh dipakai sama sekali.

Adegan WorldView-2 di Ngawi, direkam 25 Mei 2023 pada resolusi 2 meter dengan empat kanal, tidak memenuhi syarat itu. Titik tolaknya sendiri sudah rapuh: 100 persen piksel melanggar kendala non-negatif, 25,5 persen di antaranya menghasilkan solusi ekstrem, dan fraksi rata-rata Cihurang mencapai 0,7901 sementara IR64 jatuh tepat di nol. Ketiga perlakuan perbaikan, ketika diuji pada titik tolak serapuh itu, sama-sama **mengubah urutan dominasi**:

Perlakuan	Galat rekonstruksi	Piksel ekstrem	Urutan dominasi
Apa adanya	0,3604	25,5 persen	Ciherang > Inpari32_WBC > Inpari32
Vektor koreksi per kanal	0,0665	14,5 persen	berubah
Setarakan rerata per kanal	0,1378	1,2 persen	berubah

Dibaca dengan kerangka bagian 13.6, tabel ini menuntun pada kesimpulan yang sama seperti pada Bab 12 — perlakuan perbaikan ditolak karena membalik kesimpulan. Hanya saja, kesimpulan itu belum sah.

Pada Bab 12, penolakan tersebut sah karena titik tolaknya telah divalidasi secara independen. Dominasi Mekongga bukan hasil satu percobaan. Ia bertahan pada 15 kombinasi Speclib, 5 sensor, 2 masker, 2 jendela tanggal, dan 4 skema endmember, sementara akurasi pemisahan Mekongga sendiri mencapai 100 persen. Karena acuannya kokoh, membaliknya menandakan perlakuan yang salah.

Pada WorldView-2, acuan itu tidak ada. Titik tolaknya sendiri degenerate — 100 persen piksel melanggar kendala, 25,5 persen ekstrem — dan tidak satu pun fraksinya pernah diuji terhadap kebenaran lapangan. Perubahan urutan dominasi karena itu tidak dapat ditafsirkan. Ia dapat berarti perlakuan merusak hasil, seperti pada Bab 12; bisa juga titik tolaknya yang sejak awal salah, dan perlakuan justru menggeser ke arah yang benar. Tanpa acuan yang tervalidasi, kedua tafsiran itu tidak dapat dibedakan dari data.

Dari situ lahir syarat tambahan bagi uji ini. Uji urutan dominasi hanya sah dipakai untuk menolak bila urutan acuannya telah divalidasi secara independen. Bila titik tolaknya sendiri belum tervalidasi, perubahan urutan tidak membuktikan apa pun, dan yang harus dicari lebih dahulu adalah acuannya — yaitu data lapangan.

Pengujian ini meninggalkan dua angka yang layak dicatat. Pertama, perbedaan skala menjelaskan **89,4 persen** dari ketidakcocokan antara citra dan endmember: galat rekonstruksi turun dari 0,3463 menjadi 0,0367 begitu skala setiap kanal disetarakan, sedangkan bentuk spektrumnya sendiri sudah cukup dekat. Kedua, penyusutan itu tidak seragam antar kanal

— 0,723 pada biru, 0,654 pada hijau, 0,998 pada merah, dan 0,529 pada inframerah dekat. Rentang hampir dua kali itu menjelaskan mengapa satu faktor skala tunggal tidak dapat memperbaikinya, seperti telah ditunjukkan pada bagian 12.5.

Yang paling penting, hasil ini memperkuat kesimpulan Bab 3 dan Bab 9. Tanpa data lapangan, tidak ada cara memutuskan model mana yang benar. WorldView-2 memberi adegan keempat, dan adegan itu tidak menambah keyakinan; ia menambah satu alasan lagi mengapa data lapangan tidak dapat digantikan oleh pengujian mana pun.

13.7 Yang perlu diingat dari bab ini

Pertama, RMSE dan akurasi bergerak berlawanan arah dalam kasus ini. Pada penskalaan skalar $k=0,40$, RMSE turun hampir enam kali lipat (179,4 persen menjadi 31,7 persen) sambil akurasi turun hampir dua belas poin persen (91,1 persen menjadi 79,5 persen). Pada ekstraksi piksel murni, RMSE bahkan turun hampir delapan kali lipat (menjadi 23,0 persen), tetapi fraksinya menjadi kacau sehingga akurasinya tidak dapat dilaporkan sebagai satu angka. Angka yang bergerak berlawanan arah tidak boleh dipakai bersama untuk memilih model.

Kedua, RMSE turun ketika endmember diperkecil karena FCLS invarian skala — fraksi tidak berubah, hanya galat yang berubah. RMSE juga turun ketika kelas ditambah, karena kelas penampung menelan sisa. Kedua-duanya menyesatkan.

Ketiga, cakupan hull adalah kenyataan fisik, bukan cacat. Hull kosong karena endmember diukur dari kanopi sedangkan piksel memuat tanah, air, dan pematang. Mengisi hull berarti melawan kenyataan; itulah yang dilakukan keempat pendekatan yang gagal.

Keempat, piksel ekstrem adalah indikator yang paling dapat diandalkan, karena tidak dapat diturunkan dengan cara-cara aritmetis yang menyesatkan RMSE. Tetapi ia harus dibaca bersama akurasi, karena ekstrem juga dapat turun karena alasan yang salah.

Kelima, konsistensi urutan dominasi adalah uji yang murah dan menangkap kesalahan yang lolos dari ukuran lain. Koreksi per kanal ditolak terutama karena membalik urutan dominasi.

Keenam, kerangka penilaian yang benar bertumpu pada akurasi pemisahan, konsistensi urutan dominasi, dan piksel ekstrem — tiga ukuran yang searah dengan tujuan dan tidak dapat dimanipulasi. RMSE dan cakupan hull tetap dilaporkan sebagai diagnostik, tetapi tidak dipakai untuk memilih.

Ketujuh, sebagai penutup bagian ini: pelajaran terbesar dari seluruh pekerjaan bukanlah bahwa empat pendekatan itu gagal. Pelajaran itu adalah bahwa **keempatnya gagal sambil membuat angka-angka terlihat membaik**. Kegagalan yang menyesatkan jauh lebih berbahaya daripada kegagalan yang jelas, karena ia mengundang pengulangan. Sebab itu mencatat mengapa sesuatu gagal — bukan hanya bahwa ia gagal — adalah bagian dari pekerjaan yang tidak boleh dilewatkan.

Kerangka ini juga membawa konsekuensi bagi cara laboratorium melaporkan hasilnya kepada pengguna. Bila hanya angka RMSE yang dilaporkan, penerima laporan akan menyimpulkan bahwa endmember yang diperkecil lebih baik — padahal sebaliknya. Karena itu laporan harus memuat, sekurang-kurangnya, akurasi pemisahan per varietas, urutan dominasi, dan persentase piksel ekstrem, disertai pernyataan terbuka tentang apa yang belum tervalidasi. Fraksi absolut varietas belum pernah diuji terhadap kebenaran lapangan; yang telah diukur adalah akurasi pemisahan spektral, bukan akurasi pemetaan tematik. Perbedaan kedua hal itu penting dan harus dinyatakan terbuka, supaya angka-angka yang dilaporkan tidak dibaca melebihi apa yang sebenarnya dibuktikan.

Ada satu sikap yang menyatukan seluruh kerangka ini. Sikap itu dapat dirumuskan dalam satu kalimat: **sebuah angka hanya berguna bila kita tahu apa yang ia ukur, dan bila ia tidak dapat diperbaiki dengan cara yang merusak**. RMSE dan cakupan hull gagal pada kedua syarat itu. Akurasi pemisahan, konsistensi urutan dominasi, dan piksel ekstrem lulus pada keduanya. Memilih metrik, dengan demikian, bukan urusan selera teknis, melainkan bagian dari ketelitian ilmiah: memakai ukuran yang tidak dapat dibengkokkan untuk membenarkan hasil yang kita inginkan.

BAB XIV KERANGKA KERJA DAN ARAH LANJUT

14.1 Mengapa kerangka kerja disusun

Tiga belas bab sebelumnya melaporkan teori, metode, hasil, dan — yang paling penting — kegagalan. Bab 15 melengkapinya dengan peninjauan ulang terhadap dua artikel yang lebih dahulu terbit dari laboratorium yang sama. Dengan begitu, kerangka kerja di bab ini berdiri di atas temuan yang sudah diperiksa terhadap pekerjaan sebelumnya.

Bab ini menyatukan semuanya menjadi satu kerangka kerja yang dapat dipakai sebagai acuan operasional.

Kerangka kerja ini disusun karena alasan yang praktis. Pekerjaan yang dilaporkan dalam buku ini menghabiskan waktu yang besar untuk mencoba pendekatan yang ternyata gagal. Bila pengalaman itu tidak dibukukan, laboratorium berikutnya akan mengulangi jalan yang sama. Itu sebabnya kerangka kerja ini memuat bukan hanya apa yang harus dilakukan, tetapi juga apa yang **tidak perlu dicoba lagi**.

Ada alasan kedua yang lebih halus. Kerangka kerja bukan sekadar daftar langkah; ia adalah cara berpikir. Ketika sebuah pekerjaan penginderaan jauh gagal, penyebabnya jarang terletak pada satu baris kode. Penyebabnya biasanya tersebar di beberapa keputusan yang diambil lebih awal — pemilihan data, pemilihan kelas, metrik penilaian — dan masing-masing keputusan itu tampak wajar pada saat diambil. Kerangka kerja yang disusun di sini mencoba menempatkan setiap keputusan pada tempatnya. Dengan begitu, keputusan yang salah dapat dikenali lebih cepat, ketika biaya memperbaikinya masih murah.

Satu prinsip menjiwai seluruh bab ini dan seluruh alur kerja yang dibahas di dalamnya: **uji sebelum memproses, dan ukur dengan ukuran yang benar**. Kalimat itu tampak sederhana, tetapi seluruh isi buku ini pada dasarnya adalah penjabaran dari kalimat tersebut. Kegagalan yang dilaporkan pada Bab 11 dan Bab 12 bukan kegagalan menjalankan program, melainkan kegagalan menilai program dengan ukuran yang tepat.

14.2 Aturan penilaian hasil

Bagian ini adalah bagian terpenting dari kerangka kerja, karena salah menilai membuat pekerjaan yang sia-sia dilaporkan sebagai keberhasilan.

Jangan pakai RMSE untuk memilih model. Pada penskalaan skalar $k=0,40$, RMSE turun dari 179,4 persen menjadi 31,7 persen — hampir enam kali — sementara akurasi pemisahan turun dari 91,1 persen menjadi 79,5 persen. Kedua ukuran itu bergerak berlawanan arah. Memilih berdasarkan RMSE berarti memilih hasil yang lebih buruk.

Jangan pakai cakupan hull (hull coverage) sebagai sasaran. Cakupan hull dapat dinaikkan dari nol menjadi 51,6 persen dengan ekstraksi piksel murni (pure pixel), dan hasilnya justru lebih buruk. Hull adalah **diagnostik**, bukan tujuan.

Jangan pakai F1 untuk masker (mask) pada kelas tidak seimbang. Masker yang menjawab "semua padi" memperoleh F1 70,9 persen, hampir sama dengan masker sungguhan (71,8 persen). Gunakan MCC dan kappa.

Metrik yang sah adalah sebagai berikut.

Keperluan	Metrik	Ambang
Kualitas pemisahan varietas	Akurasi matriks kekeliruan piksel murni	> 85% layak
Kualitas masker padi	MCC	> 0,4 sedang, > 0,6 kuat
Kestabilan solusi	Persentase piksel ekstrem	< 1% baik
Konsistensi	Urutan dominasi antar percobaan	harus stabil

Satu metrik perlu ditekankan: **persentase piksel ekstrem (extreme pixel) adalah indikator yang paling dapat diandalkan.** Kenaikannya selalu menandakan bahwa solusi terdorong ke batas. Artinya, endmember (endmember) tidak mencakup piksel yang diuraikan. Pada uji ini, ia naik dari 0,004 persen menjadi 3,815 persen ketika jendela tanggal diperbaiki. Kenaikan itu mencegah kesimpulan yang terlalu cepat bahwa jendela baru lebih baik.

14.3 Alur kerja operasional

Alur kerja enam tahap pada Bab 9 dirangkum kembali di sini sebagai acuan singkat.

Tahap	Tindakan	Kriteria henti
1	Pilih endmember SpecLib	—
2	Uji: rasio singular, jarak	Akurasi < 85% →

Tahap	Tindakan	Kriteria henti
	antar kelas, matriks kekeliruan	berhenti
3	Pilih sensor: Sentinel-2 (3 kanal red-edge)	Tanpa red-edge → berhenti
4	Tentukan jendela dari fenologi MODIS (persentil 25–75 pembungaan)	Tanpa data fenologi → jangan menebak
5	Pisahkan padi: NDVI, NDWI, SCL, diperkuat fenologi	—
6	Jalankan FCLS tervektor, endmember apa adanya	Laporkan piksel ekstrem

Tiga keputusan tetap yang perlu dipatuhi:

Endmember dipakai apa adanya. Tidak diskalakan, tidak dikoreksi per kanal (band). Sudah diuji, dan penskalaan menurunkan akurasi.

Masker non-padi tidak dicampurkan ke dalam penguraian. Endmember air dan tanah dipakai untuk **memask**, bukan untuk menguraikan. Menambahkannya ke dalam penguraian menaikkan cakupan hull, tetapi menurunkan akurasi padi dari 91,1 menjadi 88,3 persen.

Jendela tanggal ditentukan dari fenologi (phenology). Jangan memakai jendela lebar empat bulan. Jendela selebar itu mencampur fase tumbuh dan merusak asumsi model campuran linear.

14.4 Yang tidak perlu dicoba lagi

Bagian ini adalah hasil paling berharga dari pekerjaan ini, dan paling perlu diwariskan.

Penskalaan endmember — skalar maupun vektor — tidak memperbaiki hasil. FCLS dengan kendala jumlah-satu bersifat invarian terhadap penskalaan seragam: fraksi (fraction) tidak berubah, hanya RMSE yang berubah. Selain itu, mengecilkan endmember tanpa mengubah derau (noise) citra memperburuk rasio sinyal terhadap derau. Jarak antar kelas menyusut 45 sampai 60 persen, dan akurasi turun.

Menambahkan kelas non-padi ke dalam penguraian tidak memperbaiki hasil. Cakupan hull naik menjadi 85 persen, tetapi kelas

"tanah" menyerap fraksi 0,2552 dan sebagian padi ikut tertelan. Akurasi turun; IR64 yang sebelumnya 59,7 persen turun menjadi 53,8 persen.

Koreksi per kanal tidak memperbaiki hasil. Meskipun secara teori lebih benar daripada penskalaan seragam — karena rasio per kanal memang tidak seragam, berkisar 0,37 sampai 0,60 — hasilnya tetap lebih buruk: akurasi 81,6 persen dibandingkan 91,1 persen.

Ekstraksi piksel murni dari citra 30 meter tidak menyelesaikan masalah. Meskipun cakupan hull naik menjadi 51,6 persen dan RMSE turun menjadi 23,0 persen, piksel ekstrem justru naik dua kali, dan fraksi yang dihasilkan tidak masuk akal — dua kelompok yang terbentuk sama-sama paling cocok dengan varietas (variety) Inpari32. Penyebabnya, piksel "murni" pada resolusi 30 meter tetap merupakan campuran. Akibatnya, algoritme menemukan arah variasi spektral yang mencakup perbedaan fase dan kondisi tanaman, bukan perbedaan varietas.

Keempat hal di atas sudah diuji dengan angka, bukan diduga. Jangan diulangi tanpa alasan baru yang kuat.

14.5 Arah pengembangan yang menjanjikan

Kerangka kerja yang baik tidak hanya menutup jalan buntu, tetapi juga menunjukkan jalan yang terbuka. Ada tiga arah yang menjanjikan.

Pertama, dan paling berharga: data lapangan. Ini menutup keterbatasan terbesar yang dinyatakan pada Bab 10 — bahwa yang diukur baru akurasi pemisahan spektral, bukan akurasi pemetaan tematik. Yang dibutuhkan adalah koordinat petak contoh dengan varietas yang diketahui, minimal tiga puluh petak yang tersebar, pada musim (season) tanam (cropping season) yang sama dengan citra. Dengan data itu, angka akurasi berubah dari pernyataan tentang spektrum menjadi pernyataan tentang peta.

Kedua, endmember per fase tumbuh. Endmember SpecLib yang dipakai mewakili padi pada fase puncak. Untuk citra pada fase lain, diperlukan endmember fase tersebut. Penskalaan bukan penggantinya — sudah diuji. Yang diperlukan adalah mengukur spektrum padi pada beberapa fase, atau menurunkan endmember per fase dari deret waktu (time series) citra.

Ketiga, sensor dengan kanal lebih banyak. Untuk memisahkan IR64 dari Ciherang, diperlukan kanal yang lebih halus di daerah red-edge. Sentinel-2 dengan tiga kanal red-edge sudah mencukupi untuk empat varietas; yang kelima memerlukan hiperspektral atau setidaknya sensor dengan kanal red-edge lebih rapat.

14.6 Daftar periksa operasional

Bagian ini menyusun kerangka kerja di atas menjadi daftar periksa yang dapat dicetak dan dipakai langsung di meja kerja. Daftar periksa disusun berurutan, dan setiap butir ditandai dengan kotak yang dapat dicentang. Tujuannya bukan menambah birokrasi, melainkan mencegah agar keputusan yang mahal tidak diambil tanpa pengecekan yang murah.

A. Sebelum menyentuh citra

- [] Tentukan pertanyaan penelitian secara eksplisit: varietas mana yang ingin dipisahkan, dan untuk keperluan apa peta itu dipakai.
- [] Periksa ketersediaan endmember pada basis data Speclib untuk kanal-kanal sensor yang akan dipakai. Pastikan jumlah kelas pada sesuai kebutuhan.
- [] Hitung rasio singular (singular-value ratio) endmember pada kanal sensor yang dipilih. Catat nilainya (pada pekerjaan ini 410,8 untuk sembilan kanal Sentinel-2).
- [] Hitung matriks jarak spektral (spectral distance) antar seluruh pasangan kelas. Tandai pasangan dengan jarak terpendek, dan periksa apakah pasangan itu masuk akal secara agronomis.
- [] Jalankan uji matriks kekeliruan (confusion matrix) pada piksel sintesis pada derau nol. Akurasi harus 100 persen; bila tidak, periksa implementasi lebih dahulu sebelum menyalahkan data.
- [] Jalankan uji yang sama pada derau realistis 0,010. Bila akurasi total di bawah 85 persen, **hentikan** dan tinjau kembali daftar endmember.
- [] Catat pasangan kelas yang paling sering tertukar, karena pasangan itu menentukan batas kemampuan peta yang akan dihasilkan.

B. Sebelum mengunduh citra

- [] Pastikan sensor yang dipilih memiliki kanal red-edge. Bila tidak, hentikan.

- [] Unduh data fenologi MODIS MOD13Q1 untuk **tahun tanam yang sama** dengan citra sasaran, bukan tahun yang berdekatan.
- [] Hitung tanggal pembungaan (puncak EVI) per piksel, lalu tentukan jendela komposit (composite) sebagai persentil (percentile) 25 sampai 75 dari sebaran tanggal itu.
- [] Bandingkan jendela hasil hitungan dengan tanggal citra yang akan dipakai. Bila selisihnya besar, jangan menebak — ulangi hitungan fenologi.
- [] Catat durasi musim tanam (median 92 hari pada pekerjaan ini) dan panjang fase generatif (median 29 hari) sebagai pengendali kewajaran.

C. Sebelum menjalankan penguraian

- [] Terapkan masker padi: $NDVI > 0,35$, $NDWI < 0$, dan SCL sah.
- [] Perkuat masker dengan penanda fenologi: ada genangan ($NDFI \geq 0,10$), durasi musim 60 sampai 150 hari, dan puncak $EVI \geq 0,35$.
- [] Nilai kualitas masker dengan MCC dan kappa, bukan F1. Catat nilainya (MCC 0,491 untuk gabungan NDVI atau fenologi pada pekerjaan ini).
- [] Periksa keberadaan nilai kosong pada data dengan **isfinite per baris**. Baris sambungan mosaik yang kosong dapat mengembalikan nilai kosong pada seluruh larik hasil.
- [] Pastikan endmember dipakai apa adanya — tanpa penskalaan, tanpa koreksi per kanal.

D. Setelah penguraian dijalankan

- [] Laporkan fraksi per varietas beserta jumlah piksel yang menjadi dasar hitungan.
- [] Laporkan persentase piksel ekstrem. Bila di atas 1 persen, hasil perlu disertai peringatan.
- [] Periksa konsistensi urutan dominasi varietas terhadap percobaan sebelumnya. Urutan yang berubah tiba-tiba adalah tanda masalah.
- [] Uji struktur spasial: bandingkan keragaman antar blok dengan sebaran acak, dan hitung korelasi piksel bertetangga. Pada pekerjaan ini rasionya 27,2 kali dan korelasinya 0,714.

- [] Tuliskan secara eksplisit batas kemampuan peta: varietas mana yang tidak dapat dipisahkan, dan bahwa fraksi absolut belum tervalidasi lapangan.

Daftar periksa ini sengaja dibuat panjang pada bagian awal dan pendek pada bagian akhir. Alasannya sejalan dengan prinsip yang sudah disampaikan: **kegagalan termurah adalah kegagalan yang terdeteksi paling awal**. Pengecekan pada bagian A dan B memakan waktu menit, tetapi dapat menghemat hari. Pengecekan pada bagian D memakan waktu menit pula, tetapi menentukan apakah hasil boleh diserahkan kepada pengguna.

14.7 Rencana pengumpulan data lapangan

Arah yang paling berharga, sebagaimana disampaikan pada Bagian 13.5, adalah data lapangan. Sebab itu bagian ini menyusun rencana pengumpulan data yang konkret, sehingga pekerjaan lapangan tidak dilakukan secara sporadis melainkan mengikuti rancangan yang dapat dipertanggungjawabkan.

Jumlah dan sebaran petak. Sasaran minimum adalah tiga puluh petak contoh dengan varietas yang diketahui. Tiga puluh petak itu tidak boleh menumpuk di satu lokasi; sebarannya harus mewakili keragaman wilayah kajian. Sebagai panduan, sebaran itu dapat mengikuti pola sebaran padi yang sudah ditemukan pada Bab 10: kuadran (quadrant) barat daya memuat 87,0 persen piksel padi, sedangkan kuadran timur laut hanya 16,5 persen. Karena sebaran padi tidak merata, jumlah petak per kuadran harus disesuaikan dengan luas padi di kuadran itu, bukan dibagi rata. Bila memungkinkan, setiap petak berukuran minimal 60 kali 60 meter, sehingga setidaknya empat piksel Sentinel-2 30 meter berada di bagian dalam petak dan tidak terpengaruh piksel tepi.

Waktu pengamatan. Pengamatan lapangan harus dilakukan pada **musim tanam yang sama** dengan citra yang akan divalidasi. Berdasarkan hasil fenologi pada Bab 7, tanggal pembungaan median jatuh pada 22 Maret 2026, dengan jendela pembungaan berkisar 24 Februari sampai 3 Mei 2026. Sebab itu kunjungan lapangan sebaiknya dilakukan pada rentang waktu itu, sedekat mungkin dengan tanggal perekaman citra Sentinel-2 yang dipakai. Pengamatan pada fase vegetatif atau fase bera (fallow) akan mencatat spektrum yang berbeda dari spektrum puncak, sehingga tidak dapat dipakai untuk memvalidasi endmember fase puncak.

Alat yang dibutuhkan. Peralatan minimum meliputi penerima GNSS untuk mencatat koordinat petak dengan ketelitian beberapa meter, spektoradiometer bila pengukuran spektrum padi akan diulang, kamera untuk mendokumentasikan kondisi petak, dan formulir pencatatan lapangan. Bila spektoradiometer tidak tersedia, prioritas tetap diberikan pada pencatatan koordinat dan identitas varietas. Data itulah yang paling langsung menutup keterbatasan akurasi pemetaan tematik.

Format pencatatan. Setiap petak dicatat dengan sekurang-kurangnya delapan medan: identitas petak, tanggal dan jam pengamatan, koordinat sudut-sudut petak, varietas yang ditanam (nama varietas sebagaimana dikenal petani dan nama yang sesuai daftar Speclib), umur tanaman dalam hari setelah tanam, fase tumbuh pada saat pengamatan, kondisi petak (misalnya tergenang, lembap, atau kering), dan catatan tambahan mengenai keadaan sekitar. Format ini harus konsisten antar-pengamat. Ketidakkonsistenan pencatatan lebih sulit diperbaiki daripada kekurangan jumlah petak.

Verifikasi (verification) identitas varietas. Sumber informasi varietas harus dicatat dengan jelas. Keterangan dari petani perlu diverifikasi silang dengan label benih, catatan penyuluh, atau dokumen pengadaan bila tersedia. Kesalahan identitas varietas di lapangan akan tampak sebagai kesalahan akurasi peta, padahal sumbernya terletak pada cara mengamati. Sebab itu verifikasi identitas varietas sama pentingnya dengan ketelitian koordinat.

Pemanfaatan hasil. Setelah data lapangan terkumpul, akurasi yang dapat dihitung bukan lagi akurasi pemisahan spektral, melainkan akurasi pemetaan tematik: seberapa sering varietas yang dipetakan benar-benar sesuai dengan varietas yang ditanam. Angka inilah yang selama ini belum tersedia, dan angka inilah yang mengubah peta dari pernyataan tentang spektrum menjadi pernyataan tentang lahan. Data yang sama juga memungkinkan menilai fraksi absolut, yaitu seberapa dekat nilai fraksi hasil penguraian dengan proporsi varietas yang sebenarnya di lapangan.

14.8 Rencana pengembangan perangkat lunak

Kerangka kerja ini hanya bermanfaat bila dijalankan dengan alat yang tepat. Sebab itu pengembangan perangkat lunak laboratorium

sebaiknya mengikuti kerangka kerja, bukan berjalan sendiri. Ada empat prinsip yang perlu dipegang.

Pertama, perangkat lunak harus memaksakan urutan enam tahap. Alih-alih menyediakan satu fungsi besar yang menjalankan seluruh proses sekaligus, perangkat lunak sebaiknya menyediakan fungsi terpisah untuk setiap tahap, dengan pemeriksaan otomatis di antara tahap. Bila akurasi uji endmember di bawah 85 persen, program harus berhenti dan memberi pesan, bukan melanjutkan ke pengunduhan citra. Pengecekan otomatis semacam ini menerjemahkan kriteria henti menjadi kode. Dengan begitu, disiplin tidak bergantung pada ingatan pengguna.

Kedua, perangkat lunak harus melaporkan metrik yang sah, bukan yang menyesatkan. Setiap hasil sebaiknya memuat akurasi matriks kekeliruan, MCC masker, persentase piksel ekstrem, dan urutan dominasi varietas. Sebaliknya, RMSE dan cakupan hull boleh dilaporkan sebagai diagnostik, tetapi tidak boleh dipakai sebagai kriteria untuk memilih secara otomatis. Perangkat lunak yang memilih model berdasarkan RMSE akan memilih model terburuk, sebagaimana ditunjukkan pada Bab 12.

Ketiga, perangkat lunak harus tahan terhadap jebakan teknis yang sudah diketahui. Beberapa jebakan pada pekerjaan ini memakan waktu yang besar dan sudah terdokumentasi. Perangkat lunak sebaiknya memeriksa `isfinite` per baris sebelum menjalankan solver; menghindari operasi yang mengalokasikan memori secara berlebihan seperti `np.ix_` pada jutaan piksel; menangani konvensi baris yang mudah terbalik pada mosaik; dan menggunakan implementasi tervektor, yang menyelesaikan dua juta piksel dalam waktu sekitar empat belas detik dibandingkan orde menit untuk implementasi per piksel.

Keempat, perangkat lunak harus membangkitkan laporan dari data, bukan dari angka yang diketik ulang. Semua tabel dan angka dalam laporan sebaiknya dibaca langsung dari berkas hasil yang dihitung ulang setiap kali program dijalankan. Angka yang diketik ulang secara manual mudah menjadi usang, dan kesalahan semacam itu sulit dilacak karena tidak menimbulkan galat program.

Sebagai arah jangka menengah, fungsi-fungsi terpisah itu dapat dibungkus menjadi satu alur kerja yang dapat dipanggil dengan satu perintah, lengkap dengan berkas konfigurasi yang menyimpan pilihan

sensor, jendela tanggal, dan daftar endmember. Dengan begitu, satu percobaan dapat diulang persis oleh orang lain hanya dengan menjalankan perintah dan berkas konfigurasi yang sama. Kemampuan mereproduksi percobaan adalah syarat penting untuk sebuah laboratorium. Tanpa itu, setiap hasil hanya dapat dipercaya oleh orang yang membuatnya.

14.9 Melatih asisten laboratorium baru dengan kerangka ini

Kerangka kerja ini juga berfungsi sebagai bahan pelatihan. Pengalaman pada pekerjaan ini menunjukkan bahwa kesalahan paling besar tidak terjadi pada tingkat keterampilan memprogram, melainkan pada tingkat pengambilan keputusan. Sebab itu pelatihan sebaiknya diarahkan pada cara menilai, bukan hanya pada cara menjalankan.

Pelatihan dapat disusun dalam empat langkah. **Langkah pertama** adalah membaca kerangka kerja dan memahami mengapa setiap tahap berada pada urutannya. Asisten baru perlu memahami bahwa urutan enam tahap bukan pilihan gaya, melainkan konsekuensi dari prinsip "uji sebelum memproses". **Langkah kedua** adalah menjalankan alur kerja pada data yang sudah ada, dengan hasil yang sudah diketahui, lalu membandingkan keluarannya dengan hasil rujukan. Perbedaan kecil wajar terjadi; perbedaan besar menandakan ada tahap yang terlewat. **Langkah ketiga** adalah mempelajari empat pendekatan yang sudah terbukti gagal, beserta angka yang membuktikan kegagalannya. Bagian ini penting karena asisten baru cenderung mengusulkan kembali pendekatan yang tampak masuk akal; mengenali bahwa usulan itu sudah pernah diuji akan menghemat waktu. **Langkah keempat** adalah menjalankan tugas kecil secara mandiri, dengan pendampingan pada tahap menilai hasil, karena di situlah kesalahan paling sering terjadi.

Satu kebiasaan perlu ditanamkan sejak awal: **setiap hasil harus disertai batas kemampuannya**. Ketika seorang asisten melaporkan peta varietas, ia harus dapat menyebutkan varietas mana yang tidak dapat dipisahkan, berapa persentase piksel ekstrem, dan bahwa fraksi absolutnya belum tervalidasi lapangan. Kemampuan menyatakan batas ini bukan tanda kelemahan, melainkan tanda pemahaman. Sebaliknya, laporan yang menyajikan peta tanpa batas kemampuannya adalah laporan yang berpotensi menyesatkan pengguna.

14.10 Pelajaran metodologis yang berlaku umum

Meskipun buku ini membahas pemetaan varietas padi, beberapa pelajarannya berlaku jauh di luar bidang penginderaan jauh. Pelajaran-pelajaran itu disampaikan di sini karena sifatnya umum dan karena buku ini adalah bahan ajar, bukan hanya laporan teknis.

Pelajaran pertama: ukuran keberhasilan menentukan arah pekerjaan. Bila ukuran yang dipakai salah, setiap langkah akan tampak sebagai perbaikan, termasuk langkah yang merusak. Pada pekerjaan ini, RMSE turun hampir enam kali dan cakupan hull naik dari nol menjadi puluhan persen, sementara hasil sebenarnya memburuk. Fenomena ini tidak khas penginderaan jauh. Ia muncul setiap kali sebuah pekerjaan dioptimalkan terhadap ukuran yang tidak mewakili tujuan sebenarnya.

Pelajaran kedua: kegagalan yang terdokumentasi sama berharganya dengan keberhasilan. Empat pendekatan yang dilaporkan pada Bab 12 tidak menghasilkan peta yang lebih baik, tetapi menghasilkan kepastian tentang apa yang tidak berhasil. Kepastian itu mencegah pekerjaan berikutnya mengulangi jalan yang sama. Dalam pekerjaan apa pun, biaya mencoba sebuah pendekatan seringkali jauh lebih besar daripada biaya mendokumentasikan mengapa pendekatan itu gagal.

Pelajaran ketiga: periksa asumsi termurah sebelum mengambil keputusan yang mahal. Prinsip "uji sebelum memproses" menerapkan gagasan ini. Pengecekan yang murah pada tahap awal dapat mencegah pemborosan yang besar pada tahap akhir. Gagasan ini berlaku pada hampir semua pekerjaan: memeriksa kelayakan sebelum berinvestasi, menguji hipotesis sebelum membangun, dan memverifikasi data sebelum menganalisis.

Pelajaran keempat: batas kemampuan adalah bagian dari hasil, bukan kelemahannya. Sebuah pekerjaan yang melaporkan secara terbuka apa yang tidak dapat dikerjakannya lebih berguna daripada pekerjaan yang hanya melaporkan keberhasilannya. Pengguna yang mengetahui batas sebuah peta dapat memakainya dengan tepat; pengguna yang tidak mengetahuinya akan memakainya secara berlebihan dan kecewa pada akhirnya.

Keempat pelajaran itu saling berkaitan. Bersama-sama, mereka membentuk satu sikap kerja: **bersikap kritis terhadap hasil sendiri, dan**

terbuka tentang apa yang belum diketahui. Sikap inilah yang membuat sebuah laboratorium dapat dipercaya, jauh lebih daripada sekadar kemampuan teknis.

14.11 Nilai dari dokumentasi kegagalan

Ada satu hal yang perlu disampaikan sebagai penutup, dan hal itu menyangkut cara bekerja, bukan teknik.

Empat pendekatan yang dilaporkan pada Bab 12 menghabiskan sebagian besar waktu pekerjaan ini. Bila dilihat dari hasil akhir — peta varietas — keempatnya tidak menghasilkan apa pun. Bila dilihat dari pengetahuan, keempatnya menghasilkan sesuatu yang lebih berharga: **kepastian tentang apa yang tidak berhasil, beserta alasannya.**

Kepastian itu mahal diperoleh. Sebelum diuji, keempat pendekatan itu tampak masuk akal. Penskalaan endmember masuk akal karena citra dan endmember berbeda skala. Menambahkan kelas non-padi masuk akal karena sawah nyata memang bercampur dengan air dan tanah. Koreksi per kanal masuk akal karena rasio per kanal memang tidak seragam. Ekstraksi piksel murni masuk akal karena metode itu memang dirancang untuk mencari endmember dari citra.

Keempatnya baru terbukti salah setelah diuji dengan angka. Dan yang membuat pengujiannya mengejutkan adalah bahwa **semuanya memperbaiki ukuran yang tampak penting** — RMSE turun, cakupan hull naik — sementara hasil sebenarnya memburuk.

Pelajaran metodologisnya berlaku di luar bidang ini: **sebuah perbaikan hanya layak disebut perbaikan bila diukur dengan ukuran yang benar.** Ukuran yang salah akan menunjukkan perbaikan pada setiap langkah, termasuk langkah yang merusak.

Sebab itu buku ini menutup bukan dengan peta varietas, melainkan dengan kerangka kerja untuk menilai apakah sebuah peta layak dipercaya. Peta dapat dibuat dengan cepat; kepercayaan pada peta memerlukan pekerjaan yang jauh lebih panjang.

14.12 Ringkasan penutup

Yang bekerja: endmember SpecLib apa adanya (akurasi 91,1 persen), empat dari lima varietas dapat dipetakan, jendela tanggal dari fenologi MODIS, masker padi dari gabungan NDVI dan fenologi (MCC

0,491), dan penguraian tervektor yang menyelesaikan dua juta piksel dalam sekitar empat belas detik.

Yang tidak bekerja: pemisahan IR64 dari Ciherang (batas fisik, jarak 0,1222), Landsat untuk pemisahan varietas, dan empat pendekatan perbaikan yang dibahas pada Bab 12.

Yang harus diingat: RMSE menyesatkan — ia turun hampir enam kali sambil akurasi turun hampir dua belas poin persen. Hull yang kosong itu wajar, karena endmember diukur pada kanopi (canopy) sedangkan piksel satelit memuat tanah, air, dan pematang — dan kondisi itu terjadi pada sensor mana pun, sebagaimana dikonfirmasi oleh Landsat 9. Endmember SpecLib sudah benar secara spektral, dengan korelasi bentuk 0,991 sampai 0,998. Dan piksel ekstrem adalah indikator yang paling dapat diandalkan.

Yang perlu dibaca bersama Bab 15: kerangka kerja ini telah diperiksa ulang terhadap dua artikel sebelumnya. Tiga butirnya berubah setelah uji kebermaknaan (significance test): **rasio singular** ditambahkan sebagai penanda mutu yang sah (korelasi $-0,939$, $p < 0,0001$), sedangkan **jarak spektral** dan **akurasi berpasangan** tidak lagi dipakai sebagai ukuran mutu karena keduanya tidak terbukti meramalkan akurasi. Menentukan fase padi juga dipastikan harus memakai tanggal dari puncak EVI, bukan rasio EVI rata-rata di dalam jendela komposit (Bab 15.8).

Buku ini adalah bahan ajar internal, dan isinya akan berkembang seiring pekerjaan berikutnya. Yang diharapkan tetap berlaku adalah kerangka kerjanya: **uji sebelum memproses, dan ukur dengan ukuran yang benar.**

15.1 Mengapa bab ini ada

Buku ini berdiri di atas dua artikel yang lebih dahulu terbit dari laboratorium yang sama. Artikel pertama (Cipta dkk., 2022) [13] menguji penguraian spektral (spectral unmixing) linear (linear spectral unmixing) pada citra Landsat 8 untuk memetakan varietas (variety) padi di Indramayu. Artikel kedua (Cipta dkk., 2024) [14] menguji pendekatan berbasis fenologi (phenology) di Ngawi dengan empat indeks spektral dan validasi (validation) lapangan. Keduanya merupakan titik tolak pekerjaan ini, dan keduanya dilaporkan secara terbuka sesuai bukti yang tersedia pada waktu itu.

Bab ini bukan pembantahan. Bab ini adalah pemeriksaan ulang dengan data, sensor, dan metode yang belum tersedia ketika kedua artikel itu ditulis. Yang diuji bukan niat atau ketelitian penulisnya, melainkan **klaim-klaim yang dapat diuji ulang**. Sebagian klaim bertahan dan justru menguat. Sebagian lain perlu dikoreksi. Dan sebagian kecil ternyata tidak dapat diuji dengan data yang ada sekarang — itu pun harus dikatakan.

Alasannya sederhana: sebuah klaim yang tidak pernah diuji ulang akan terus dikutip sebagai kebenaran, padahal kebenarannya bergantung pada data yang dipakai mengujinya.

15.2 Cara peninjauan dilakukan

Peninjauan ini memakai empat aturan yang ditetapkan lebih dahulu.


Pertama, angka dibandingkan hanya bila kondisi pengukurannya sebanding. Wilayah, musim (season) tanam (cropping season), dan sensor yang berbeda membuat perbandingan langsung menjadi menyesatkan. Artikel 2022 [13] memakai citra Indramayu Maret 2021 dengan Landsat 8. Artikel 2024 memakai Ngawi 2020–2023 dengan Landsat 8 dan Worldview-2. Buku ini memakai Indramayu 2025–2026 dengan Sentinel-2 dan Landsat 9. Setiap angka dalam bab ini disebutkan wilayah, musim, dan sensornya.

Kedua, acuan penilaian harus bebas. Ini aturan yang paling menentukan, dan alasannya dijelaskan pada bagian 15.5.

Ketiga, angka yang diuji harus berasal dari data yang sama. Data mentah tidak diubah; setiap angka dapat ditelusuri ke berkas hasilnya.

Keempat, yang tidak dapat diuji dinyatakan tidak dapat diuji. Tidak ada angka pengganti, tidak ada interpolasi, tidak ada perkiraan yang disamakan sebagai hasil.

15.3 Klaim artikel 2022: apa yang bertahan, apa yang gugur



Gambar 15.1. Alur kerja yang dipakai artikel 2022: penentuan endmember, penentuan fase reproduktif dari MODIS, penerapan ambang pada Landsat 8, lalu penguraian spektral.

Artikel 2022 menyimpulkan bahwa metode penguraian spektral dengan Landsat 8 masih "kesulitan mengidentifikasi varietas padi", dan menyebut dua penyebab: resolusi spasial yang rendah serta spektral library yang terbatas. Kedua penyebab itu dapat diuji.

15.3.1 Klaim "resolusi spasial rendah" — perlu dikoreksi

Resolusi spasial memang terbatas pada Landsat 8, yaitu 30 meter. Namun pengujian pada buku ini menunjukkan bahwa yang benar-benar hilang bukan ketajaman pikselnya, melainkan **kanal (band) red-edge**-nya.

Buktinya berlapis. Ketika spektrum lima varietas diproyeksikan ke empat kanal yang tersedia di Landsat 8 (biru, hijau, merah, inframerah

dekat) dan dibandingkan dengan sembilan kanal Sentinel-2, jarak antar-kelas **menyusut antara 23 dan 56 persen** bergantung pada pasangan yang diuji. Untuk pasangan tersulit, Ciherang dan IR64, jaraknya menyusut dari 0,1222 pada sembilan kanal menjadi 0,0610 pada empat kanal — **berkurang 50,1 persen**.

Ukuran kedua lebih tegas lagi. **Rasio singular (singular-value ratio)** matriks endmember (endmember) — perbandingan nilai singular (singular value) terbesar terhadap terkecil, yang mengukur seberapa "gepeng" ruang spektrum yang tersedia — bernilai **79,4** untuk Landsat 8 empat kanal dan **410,8** untuk Sentinel-2 sembilan kanal. Ruang spektrum yang lebih gepeng membuat kelas-kelas saling bertumpuk, dan penguraian spektral kehilangan daya pisah.

Yang penting: **rasio singular terbukti berkorelasi dengan kemampuan pemisahan**. Korelasinya dengan akurasi adalah **-0,939** ($p < 0,0001$, $n = 15$) — hubungan negatif yang sangat kuat dan berbeda nyata dari nol. Artinya rasio singular bukan sekadar ukuran deskriptif; ia benar-benar meramalkan seberapa baik penguraian akan bekerja.

Jadi bukan penguraian spektralnya yang gagal. Sensornya yang kurang. Ini perbedaan yang bukan sekadar istilah, karena konsekuensinya berbeda: bila penyebabnya resolusi, jalan keluarnya adalah piksel yang lebih kecil; bila penyebabnya kanal, jalan keluarnya adalah sensor yang berbeda.

15.3.2 Klaim "spektral library terbatas" — gugur


Endmember yang dipakai pekerjaan ini berasal dari SpecLib Sentinel-2 MSI, yaitu pustaka spektrum hasil pengukuran lapangan. Kualitasnya diuji dengan membandingkan **bentuk** spektrumnya terhadap citra, bukan nilainya. Korelasi bentuknya **0,991 sampai 0,998** — sangat tinggi.

Selanjutnya diuji apakah penskalaan endmember memperbaiki hasil. Penskalaan skalar, penambahan kelas non-padi, koreksi per kanal, dan ekstraksi piksel murni (pure pixel) diuji satu per satu. **Keempatnya menurunkan akurasi** (Bab 12). Artinya endmember SpecLib tidak perlu diperbaiki; yang perlu diperbaiki adalah sensor dan fase pengamatannya.

Dengan demikian, "spektral library yang terbatas" bukan penyebab kegagalan. Jumlah kelas lima sudah cukup; yang kurang adalah kanal.

15.3.3 Klaim "Ciherang tidak ada di piksel mana pun" — perlu tafsir ulang

Artikel 2022 melaporkan fraksi (fraction) Ciherang bernilai nol di setiap piksel, dan menafsirkan bahwa Ciherang tidak terdeteksi. Pekerjaan ini menunjukkan tafsir itu perlu diperbaiki.



Gambar 15.2. Hasil penguraian spektral artikel 2022 di Indramayu. Fraksi endmember disajikan pada sawah fase reproduktif; abu-abu = bukan sawah, kuning = sawah fase non-reproduktif.

Yang sebenarnya terjadi: **Ciherang tidak dapat dipisahkan dari IR64**. Akurasi pemisahan keduanya hanya **59,7 persen** dengan jarak spektral (spectral distance) **0,1222** — pasangan terlemah di seluruh pengujian. Ketika keduanya diuji tanpa tiga varietas lain bersaing, akurasi IR64 naik menjadi **91,4 persen**. Jadi IR64 bukan mustahil dipisahkan; ia kalah bersaing ketika kelima kelas berada dalam ruang solusi yang sama.


Karena Ciherang dan IR64 saling bertukar identitas, algoritme tidak pernah menetapkan Ciherang pada suatu piksel — bukan karena Ciherang tidak ada di lapangan, melainkan karena fraksinya habis terbagi ke IR64 dan kelas lain. **Fraksi nol adalah tanda kegagalan pemisahan, bukan tanda ketiadaan.**

Tafsir baru ini justru **konsisten** dengan temuan 2022 yang lain: artikel itu melaporkan IR64 hanya mencapai fraksi 0,440 — tidak pernah

mendekati 1,0. Dua kelas yang sama-sama lemah adalah gejala yang sama, dilihat dari dua sisi.

15.4 Klaim artikel 2024: apa yang bertahan, apa yang gugur

Artikel 2024 memakai pendekatan berbasis fenologi di Ngawi, dengan empat indeks spektral, ambang (threshold) otomatis Otsu, dan validasi lapangan pada 15 titik.



Gambar 15.3. Kurva fenologi padi dari artikel 2024: indeks spektral NDVI, EVI, LSWI, dan MNDWI beserta hamburan balik SAR polarisasi VH, dari penggenangan sampai panen.

15.4.1 Klaim "empat indeks lebih baik daripada dua" — cenderung gugur

Untuk menguji klaim ini, kanal SWIR Sentinel-2 (B11 dan B12) diunduh sehingga MNDWI dan LSWI dapat dihitung. Sebelumnya keduanya belum tersedia, sehingga klaim ini belum pernah dapat diuji pada data buku ini.

Hasilnya: **menambahkan MNDWI dan LSWI menurunkan kemampuan memisahkan padi.** Terhadap acuan bebas (independent reference), indeks EVI tunggal dengan ambang Otsu memberi F1 **0,847**. Menambahkan MNDWI menurunkannya menjadi **0,841**. Menambahkan LSWI lebih jauh lagi menjadi **0,774**. Kelima indeks sekaligus memberi **0,744**.

Pola itu **monoton**: makin banyak indeks digabungkan, makin buruk hasilnya. Pengujian ulang dengan cara penghitungan yang berbeda (pemetaan tetangga terdekat, bukan rata-rata) memberi arah kesimpulan yang sama, dengan selisih lebih besar lagi.

Sebabnya dapat dijelaskan secara spektral. MNDWI mengukur keberadaan air permukaan. Ia memisahkan sawah tergenang dari lahan

kering, tetapi **tidak memisahkan padi dari tanaman berdaun lebar lain** yang sama-sama hijau. LSWI bahkan kurang berguna untuk padi: perbedaan nilai rata-rata antara piksel padi dan bukan padi hanya **0,036**. Kedua indeks menambah derau (noise) lebih banyak daripada menambah informasi.

Satu catatan yang perlu disampaikan secara terbuka: pengujian ini memakai sensor dan wilayah yang berbeda dari artikel 2024. Karena itu hasilnya **bukan pembatalan mutlak**, melainkan bukti bahwa klaim "empat indeks lebih baik" **tidak dapat digeneralisasi** ke luar kondisi pengujian asalnya.

15.4.2 Klaim "Otsu lebih dapat dipertanggungjawabkan" — bertahan sebagian

Otsu memang lebih baik daripada ambang manual, tetapi **hanya untuk indeks yang tepat**. Yang penting: kestabilannya berbeda jauh antar-indeks.

Untuk **NDFI**, ambang Otsu sangat stabil: rentang antar-kuadran (quadrant) hanya **0,056**. Untuk **NDVI**, ambang Otsu tidak stabil: rentangnya mencapai **0,587**, dengan simpangan 0,247 — dan di satu kuadran nilainya bahkan **negatif, -0,061**, yang secara fisis tidak bermakna untuk NDVI.

Jadi rekomendasinya bukan "pakai Otsu", melainkan **"pakai Otsu pada indeks yang histogramnya memang dwimodal"**. Memakai ambang otomatis pada indeks yang salah memberi kestabilan semu: angkanya terlihat objektif, padahal berubah liar antar-wilayah.

15.4.3 Klaim "RMSE sebagai ukuran mutu" — perlu dikoreksi

Artikel 2024 memakai RMSE sebagai ukuran ketelitian, dan melaporkan RMSE Landsat 8 (0,012) lebih baik daripada Worldview-2 (0,070).

Pekerjaan ini menunjukkan RMSE **tidak dapat dipakai menilai mutu hasil penguraian**. Korelasinya dengan akurasi hanya **+0,253**, dan dengan uji statistik nilainya **p = 0,164** — tidak berbeda nyata dari nol. Artinya RMSE tidak meramalkan apa pun tentang seberapa benar hasilnya.

Bukti yang paling gamblang muncul dari perbandingan dua setelan. Setelan Q1 dengan pemetaan Gaussian Weighting memberi **RMSE**

terbaik, 155,6 persen, tetapi akurasinya hanya **91,5 persen**. Setelan Median dengan pemetaan Nearest Band memberi **RMSE 167,8 persen** — lebih buruk — tetapi akurasinya **93,8 persen**. RMSE yang lebih baik justru disertai akurasi yang lebih buruk.

Sebabnya dijelaskan pada Bab 13: RMSE mengukur seberapa dekat hasil rekonstruksi terhadap citra aslinya, bukan seberapa benar kelas yang ditetapkan. Solusi yang mendorong fraksi ke batas simpleks (simplex) dapat menurunkan RMSE sekaligus merusak hasil.

Yang dapat dipakai sebagai ganti adalah **rasio singular** ($-0,939$, $p < 0,0001$) dan **persentase piksel ekstrem (extreme pixel)**. Keduanya meramalkan akurasi; RMSE tidak.

15.4.4 Klaim "Landsat 8 lebih baik daripada Worldview-2" — belum dapat diputuskan

Klaim ini **tidak dapat diuji** dengan data yang tersedia sekarang, karena citra Worldview-2 belum dipakai dalam pekerjaan ini. Yang dapat dikatakan: Landsat 8 memang kalah dari Sentinel-2 untuk pemisahan varietas, dengan jarak antar-kelas menyusut 50,1 persen dan rasio singular 79,4 melawan 410,8. Tetapi itu perbandingan Landsat dengan Sentinel, bukan Landsat dengan Worldview-2. Perbandingan yang dimaksud artikel 2024 menunggu data Worldview-2 diuji.

15.5 Temuan yang mengubah cara membaca kedua artikel

Ada satu temuan yang tidak menyangkut klaim tertentu, melainkan menyangkut **cara semua angka itu diukur**. Temuan ini berlaku untuk artikel 2022, artikel 2024, dan buku ini sekaligus.

Acuan padi yang dipakai pekerjaan ini bersifat sirkular. Masker (mask) padi acuan — disebut `padi_s2` — didefinisikan oleh **NDVI Sentinel-2 > 0,35**. Karena itu setiap angka akurasi masker yang diukur terhadap `padi_s2` sesungguhnya mengukur seberapa sesuai suatu metode dengan definisi yang dipakai membuat acuannya. Ini bukan pengukuran yang bebas.

Akibatnya dapat ditunjukkan dengan angka. Terhadap acuan sirkular itu, NDVI dengan ambang manual menang (F1 0,732). Tetapi terhadap acuan **bebas** — kelas cropland ESA WorldCover — NDVI manual hanya memberi F1 **0,703**, sedangkan EVI dengan ambang Otsu memberi **0,847**.

Masker majemuk yang dipakai buku pada analisis awal hanya memberi **0,487**.

Pola yang harus diingat: **bila peringkat metode berubah antara acuan bebas dan acuan sirkular, itu tanda acuannya yang menyesatkan — bukan tanda metodenya tidak stabil**. Aturan praktisnya sederhana: jangan pernah menilai masker dengan acuan yang didefinisikan oleh masker itu sendiri.

Hal yang sama berlaku untuk artikel 2022 yang memakai ambang $NDVI > 0,70$. Angka akurasi yang diukur terhadap acuan semacam itu harus dibaca sebagai **pemeriksaan konsistensi**, bukan sebagai akurasi. Ini tidak mengurangi nilai artikelnya, tetapi mengubah cara angkanya sebaiknya dikutip.

15.6 Yang memperkuat kedua artikel

Peninjauan yang hanya melaporkan koreksi akan menyesatkan, karena sebagian besar temuan kedua artikel justru bertahan. Yang bertahan, dan kini dengan bukti tambahan:

Penguraian spektral linear memang dapat memisahkan varietas padi. Buku ini memisahkan empat dari lima varietas dengan akurasi 91,1 persen; dengan setelan terbaik (Median, Nearest Band) mencapai 93,8 persen, dan rata-rata lintas 28 pengujian 93,9 persen. Keraguan artikel 2022 tentang kemampuan metode ini terjawab: metodenya mampu, asalkan sensornya memadai.

Pola dominasi satu varietas bertahan. Artikel 2022 melaporkan Inpari 32 dominan (30.738,65 ha), dan artikel 2024 juga melaporkan Inpari 32 dominan. Buku ini menemukan pola yang sama di Indramayu 2025–2026, yaitu satu varietas mendominasi secara konsisten — hanya nama varietasnya berbeda (Mekongga), yang wajar karena wilayah dan musimnya berbeda. Pola dominasi itu bertahan di seluruh 15 kombinasi setelan, tiga sensor, dua masker, dua jendela waktu, dan empat skema endmember. Ini temuan yang kuat.

Fenologi adalah cara yang benar untuk menentukan jendela pengamatan. Ini inti pendekatan artikel 2024, dan terbukti pada data buku ini: panjang musim median 92 hari (p25 79, p75 109), dengan tanggal pembungaan (flowering) median 22 Maret 2026. Artikel 2024 menemukan

tiga musim tanam per tahun; buku ini menemukan pola gelombang tanam bergilir yang sejalan.

Ambang otomatis berguna, asalkan dipilih dengan tepat. Otsu terbukti sangat stabil untuk NDFI dan tidak stabil untuk NDVI. Ini menyempurnakan, bukan membatalkan, rekomendasi artikel 2024.

Batas fisik antara Ciherang dan IR64 menjelaskan temuan 2022. Perbedaan spektrum keduanya memang lebih kecil daripada derau citra. Ini alasan fisis yang menjelaskan mengapa artikel 2022 menemukan fraksi Ciherang nol — bukan kesalahan pengukuran, melainkan batas yang nyata.

15.7 Metode yang dianjurkan setelah peninjauan ini

Peninjauan ini menghasilkan rekomendasi yang lebih sempit dan lebih tegas daripada yang dapat diberikan sebelumnya, karena setiap butirnya berdasar angka yang telah diuji.

Data. Sentinel-2 MSI dengan **sebelas kanal** (B1–B9 ditambah B11 dan B12) untuk pemisahan varietas sekaligus indeks air. Landsat 8/9 hanya sebagai cadangan komplementer: cakupannya terbatas (hanya 32,7 persen piksel sehat, berbanding 71,5 persen pada Sentinel-2) dan F1 MNDWI-nya 0,452 berbanding 0,697 pada Sentinel-2. MODIS hanya untuk fenologi, bukan untuk pemetaan varietas, karena 51,3 persen sel berukuran 250 meter tercampur.

Metode. Reduksi **Median**, pemetaan **Nearest Band** (efek terbesar dari seluruh pilihan metode: +4,54 poin pada uji silang), masker padi memakai **EVI tunggal dengan ambang Otsu** atau NDVI+EVI — **bukan** kombinasi empat atau lima indeks. Penguraian memakai FCLS. Penilaian memakai **F1, MCC, dan kappa terhadap acuan bebas**; RMSE hanya sebagai diagnostik, bukan ukuran mutu.

Penentuan fase. Fase padi ditentukan dari **tanggal** yang diturunkan dari puncak kurva EVI, bukan dari rasio EVI rata-rata di dalam jendela komposit (composite). Alasannya diuji pada Bab 15.8.

Tiga tahap penentu kelayakan, dan bila salah satu gagal maka pekerjaan dihentikan: pertama, pemeriksaan geometri endmember (rasio singular); kedua, pemeriksaan masker terhadap acuan bebas; ketiga, validasi lapangan pada sekurang-kurangnya 30 petak. Tahap ketiga belum dijalankan pada pekerjaan ini.

15.8 Dua cara menentukan fase, dan mengapa yang satu harus ditinggalkan

Pekerjaan ini sempat memakai **dua cara berbeda** untuk menentukan fase padi, dan keduanya masih tersimpan di dalam kode. Perbedaan itu perlu diselesaikan karena mempengaruhi angka-angka yang dilaporkan di bab-bab sebelumnya.

Cara pertama membaca kurva EVI penuh: puncak dicari dengan argmax , lalu fase generatif ditetapkan mulai dari titik yang mencapai 60 persen amplitudo hingga puncak. Cara ini menghasilkan **tanggal**.

Cara kedua membaca EVI rata-rata di dalam jendela komposit, lalu membandingkannya terhadap basis dan amplitudo kurva penuh, dengan ambang 0,25 / 0,60 / 0,90 untuk menetapkan empat kelas. Cara ini **tidak menghasilkan tanggal apa pun** — hanya kelas.

Keduanya diuji dengan empat kriteria, dan hasilnya tegas.

Kestabilan terhadap pilihan jendela. Jendela komposit adalah keputusan yang sebenarnya sembarang. Ketika jendela digeser 20 sampai 40 hari, cara pertama mengubah kelas pada **34,6 persen** piksel; cara kedua pada **56,8 sampai 71,4 persen**. Cara pertama unggul pada setiap pergeseran dan setiap jangkar.

Lebih penting lagi, arah perubahannya berbeda. Pada cara pertama, perubahan bersifat **satu arah** (monoton): menggeser jendela ke depan memang menaikkan kelas, sesuai makna waktu. Pada cara kedua, perubahan bersifat **dua arah** — piksel dapat berpindah ke kelas yang lebih awal maupun lebih akhir tanpa pola. Kelas pada cara kedua karena itu tidak bermakna waktu.

Daya pisah kelas. Pada cara kedua, kelas "Puncak/heading" praktis **kosong** (0,4–0,5 persen); 92 sampai 98 persen piksel menumpuk hanya di dua kelas. Ambang 0,90 kali amplitudo hampir tidak pernah dicapai oleh EVI rata-rata satu jendela — hanya oleh puncak sesaat. Kelas itu tidak berdaya pisah.

Kerapatan ruang. Di sini cara kedua menang (fragmentasi 18,1 persen berbanding 25,2 persen). Tetapi keunggulan ini bukan bukti ketepatan: peta dua warna selalu tampak lebih rapat daripada peta empat warna. Karena itu keunggulan ini **tidak dijadikan dasar keputusan**.

Kesahihan agronomis: tidak dapat dihitung. Acuan yang direncanakan — puncak NDFI sebagai penanda penggenapan — ternyata cacat: puncaknya berimpit dengan puncak EVI (selisih median hanya satu hari), dan NDFI tidak pernah turun ke nilai genangan (inundation) sejati. Pada seri data ini puncak NDFI menandai puncak pertumbuhan, bukan penggenangan. Karena acuan itu gugur, jarak "tanam ke heading" yang wajar tidak dapat diukur. Tidak ada angka pengganti yang dikarang.

Keputusan. Fase padi ditentukan dari **tanggal** yang diturunkan dari puncak EVI — cara pertama. Cara kedua hanya layak dipakai sebagai **pemeriksa silang kasar** ("apakah jendela ini jatuh sebelum atau sesudah pembungaan?"), bukan sebagai pengklasifikasi.

Konsekuensi terhadap bab-bab sebelumnya perlu dinyatakan terbuka. Sebaran kelas fase pada Bab 7, Bab 9, dan Bab 11 (32,4 persen bera (fallow), 64,5 persen vegetatif, 1,1 persen generatif, 0,0 persen puncak) dihitung dengan **cara kedua**. Angka itu sah sebagai gambaran bahwa jendela lama duduk pada fase yang salah — dan memang itulah gunanya di sana. Tetapi bila sebaran kelas fase hendak dipakai untuk menarik kesimpulan agronomis, angka itu harus dihitung ulang dengan cara pertama.

Sebagai pembanding, cara pertama untuk jendela lama memberi **94,3 persen piksel pada kelas puncak** — jauh berbeda. Kedua angka itu tidak bertentangan; keduanya menjawab pertanyaan yang berbeda. Yang pertama menjawab "pada fase apa jendela ini jatuh", yang kedua menjawab "kelas fase apa yang diberikan kepada tiap piksel". Perbedaannya harus disebut agar tidak terbaca sebagai pertentangan.

Satu hal yang perlu ditegaskan: "0,0 persen pada fase puncak" pada jendela lama **bukan temuan agronomis**. Itu artefak jendela. Tanggal pembungaan median yang sebenarnya adalah 22 Maret 2026 — jauh sebelum jendela itu dimulai. Tidak ada kesimpulan apa pun tentang padi di lapangan yang boleh ditarik dari angka 0,0 persen itu.

15.9 Batas peninjauan ini

Bab ini tidak dapat menyimpulkan lebih jauh daripada yang datanya izinkan, dan batas-batasnya perlu disebut dengan jelas.

Tidak ada validasi lapangan pada pekerjaan buku ini. Seluruh angka akurasi di bab ini adalah akurasi **pemisahan spektral**, bukan akurasi **pemetaan tematik**. Tidak satu pun piksel di sini punya tanggal tanam, tanggal malai, atau tanggal panen yang diamati di lapangan. Ini perbedaan yang menentukan, dan menyamakan keduanya adalah kesalahan yang paling mudah terjadi.

Acuan bebas yang tersedia beresolusi kasar. ESA WorldCover berukuran 250 meter dan kelasnya adalah "cropland", bukan "sawah". Karena itu F1 terhadap acuan itu bersifat konservatif — nilainya cenderung **lebih rendah** daripada yang sebenarnya, karena sebagian piksel sawah tercampur dengan lahan pertanian lain di dalam satu sel.

Perbandingan antar-sensor tidak sepenuhnya setara. Sentinel-2 dibandingkan sebagai komposit 24 scene, sedangkan Landsat 9 sebagai scene tunggal. Yang dibandingkan karena itu adalah **produk siap pakai**, bukan performa sensor mentah. Sebagian selisih cakupan berasal dari jumlah scene, bukan dari sensornya.

Ukuran sampel kecil. Uji korelasi memakai 9 sampai 15 amatan. Pernyataan "tidak nyata" pada bab ini berarti "**pada jumlah amatan ini tidak terbukti ada hubungan**", bukan "tidak ada hubungan". Selain itu kelima belas kombinasi berbagi citra yang sama, sehingga tidak sepenuhnya bebas satu dari yang lain. Nilai p sebaiknya dibaca sebagai indikasi, bukan keputusan akhir.

Worldview-2 belum dinilai. Perbandingan yang dimaksud artikel 2024 menunggu data itu diuji.

Rincian sumber setiap data beserta pustaka dan perangkat lunak yang dipakai dicatat pada Bab 16.

Perbedaan wilayah dan musim tetap ada. Artikel 2022 (Indramayu, Maret 2021), artikel 2024 (Ngawi, 2020–2023), dan buku ini (Indramayu, 2025–2026) memakai wilayah dan musim yang berbeda. Setiap angka yang dibandingkan di bab ini sudah disebutkan konteksnya, tetapi pembaca harus tetap mengingat bahwa perbedaan itu tidak dapat dihilangkan sepenuhnya.

15.10 Catatan sumber gambar

Gambar 15.1 sampai Gambar 15.3 pada bab ini berasal dari dua artikel yang ditinjau, yaitu Cipta dkk. (2022) [13] dan Cipta dkk. (2024) [14]. Keduanya dipakai dengan izin penulis korespondensi, yang juga penulis buku ini. Gambar dipakai sebagaimana terbit, tanpa perubahan, agar pembaca dapat memeriksa sendiri apa yang dilaporkan kedua artikel itu.

15.11 Yang perlu diingat dari bab ini

Peninjauan ulang ini menghasilkan lima kesimpulan yang layak dibawa ke pekerjaan berikutnya.

Pertama, koreksi yang paling penting bukan pada metode, melainkan pada sebab. Artikel 2022 menyebut penyebabnya resolusi spasial. Bukti menunjukkan penyebabnya ketiadaan kanal red-edge. Perbedaan ini menentukan arah pekerjaan selanjutnya: bukan mengecilkan piksel, melainkan memilih sensor.

Kedua, menambah indeks tidak sama dengan menambah informasi. Menggabungkan lima indeks memberi hasil yang lebih buruk daripada satu indeks yang tepat. Setiap indeks yang ditambahkan membawa derau beserta sinyalnya, dan pada padi, MNDWI serta LSWI membawa lebih banyak derau daripada sinyal.

Ketiga, ukuran yang paling intuitif sering paling menyesatkan. RMSE turun ketika hasil memburuk. Akurasi berpasangan memberi nilai tertinggi pada setelan terburuk. Yang benar-benar meramalkan akurasi justru ukuran yang paling sederhana: rasio singular matriks endmember.

Keempat, acuan menentukan kesimpulan. Menilai masker dengan acuan yang didefinisikan oleh masker itu sendiri akan selalu memberi jawaban yang menyenangkan. Hanya acuan bebas yang memberi jawaban yang berguna.

Kelima, menentukan tanggal lebih berguna daripada menentukan kelas. Cara yang menghasilkan tanggal dapat diperiksa, diperbaiki, dan dipertanggungjawabkan; cara yang hanya menghasilkan kelas tidak dapat diperiksa sama sekali, karena tidak ada angka yang dapat dibandingkan dengan kenyataan.

Kelima pelajaran ini berlaku di luar kajian padi. Ia menyangkut cara menilai pekerjaan penginderaan jauh secara umum, dan itulah sebabnya bab ini diletakkan di akhir buku — bukan sebagai lampiran, melainkan sebagai bagian dari kerangka kerja yang ingin ditanamkan.

BAB XVI SUMBER DATA, PUSTAKA, DAN PERANGKAT LUNAK

Seluruh angka pada buku ini berasal dari data yang terbuka untuk publik atau dari basis data laboratorium, dan dapat ditelusuri ulang oleh pembaca. Bagian ini mencatat sumber setiap data, pustaka, dan perangkat lunak yang dipakai. Catatan itu sekaligus menjadi bentuk pengakuan (*acknowledgement*) dan membuat pekerjaan ini dapat diperiksa serta diulang.

A. Data spektral laboratorium

SpecLib — Pustaka Spektral Terbuka Laboratorium Geospasial ITS [15]. <https://geo.its.ac.id/specLib/>

Basis data endmember (endmember) spektral ini dikelola Laboratorium Geospasial, Departemen Teknik Geomatika, ITS. Datanya berasal dari spektoradiometer lapangan. Buku ini memakai lima endmember padi:

Kelas	Deskripsi	Jumlah sampel	Rentang panjang gelombang
Ciherang	Varietas Ciherang	51	400,21–999,89 nm
IR64	Varietas IR64	53	400,21–999,89 nm
Inpari32	Varietas Inpari32	51	400,21–999,89 nm
Inpari32_WBC	Inpari32 terserang wereng batang cokelat (<i>white backed planthopper</i> , WBC)	42	400,21–999,89 nm
Mekongga	Varietas Mekongga	80	400,42–999,89 nm

A.1 Protokol pengukuran lapangan

Seluruh endmember padi diukur dengan prosedur yang sama. Protokol ini dicatat lengkap karena kualitas endmember menentukan batas atas seluruh hasil penguraian — endmember yang salah membuat hasil apa pun di atasnya tidak berarti.

Aspek	Prosedur
Instrumen	Spektroradiometer genggam lapangan; cahaya tampak dan inframerah (VIS–IR) hingga ± 1.050 nm
Sampling	Setiap objek diukur dengan 30–80 repetisi untuk menangkap variabilitas spektral alami dalam satu plot
Kalibrasi	Panel referensi putih (Spectralon) diukur sebelum setiap sesi , untuk mengubah radiance (radiance) mentah menjadi reflektansi absolut (absolute reflectance)
Kondisi	Langit cerah (<i>clear sky</i>), pukul 10.00–14.00 waktu setempat, untuk menekan pengaruh sudut matahari dan tutupan awan
Metadata	Setiap pengukuran disertai koordinat GPS, tanggal, kondisi cuaca, fase pertumbuhan, dan dokumentasi foto

Rentang instrumen. Instrumen ini mengukur cahaya tampak dan inframerah (visible and infrared, VIS–IR) hingga sekitar 1.050 nanometer, sehingga wilayah kerjanya adalah tampak sampai inframerah dekat — bukan spektroradiometer tampak–SWIR berentang penuh. Hal itu konsisten dengan ujung atas berkas mentah yang berhenti di 1.040,30 nanometer, dan sekaligus menjelaskan mengapa pustaka ini tidak dapat memasok endmember untuk kanal SWIR. Perlu dicatat bahwa dokumentasi pada laman Speclib masih menyebut rentang 350–2.500 nanometer, padahal angka itu tidak sesuai dengan instrumen yang benar-benar dipakai maupun dengan berkas yang tersimpan. Buku ini memakai rentang yang terverifikasi dari data, dan laman tersebut perlu diperbarui.

Jumlah repetisi pada tabel di atas bukan angka yang seragam secara kebetulan: Ciherang 51, IR64 53, Inpari32 51, Inpari32_WBC 42, dan Mekongga 80 semuanya berada di rentang protokol 30–80. Perlu dicatat bahwa **jumlah sampel tidak seragam antarkelas**, dan ketidakseragaman itu bukan tanpa akibat: variabilitas dalam-kelas yang terukur sebagian mencerminkan berapa banyak repetisi yang diambil, bukan semata-mata sifat tanaman. Bab 4 dan Bab 10 menunjukkan bahwa variabilitas dalam-kelas inilah yang menjadi penghambat utama pemisahan varietas. Maka

pembaca perlu mengetahui bahwa sebagian variabilitas tersebut bersumber dari protokol, bukan dari tanaman.

Dua hal lain menyangkut keterbatasan protokol. **Pertama**, data pada kondisi cerah 10.00–14.00 berarti endmember mewakili **satu kondisi pencahayaan saja**; spektrum pada pagi atau sore hari, ketika sudut matahari rendah, tidak terwakili. **Kedua**, fase pertumbuhan dicatat sebagai metadata tetapi endmember yang dipakai buku ini adalah hasil reduksi seluruh sampel per kelas, sehingga variasi antarfase tidak dipisahkan. Bab 15 menunjukkan akibat dari pilihan ini: sebagian ketidakpastian pemisahan varietas bersumber dari pencampuran fase pertumbuhan di satu kelas endmember.

A.2 Pemetaan ke kanal sensor

Kurva spektral laboratorium beresolusi 0,19 nanometer, sedangkan kanal satelit memiliki lebar 20–190 nanometer. Spektrum karenanya harus dipindahkan ke kanal sensor (*convolution*). Tiga metode disediakan, dan ketiganya diuji pada Bab 5:

- **Average** — rata-rata sederhana seluruh nilai reflektansi di dalam rentang FWHM (full width at half maximum) kanal: $R_b = (1/N) \cdot \sum R(\lambda)$, untuk $\lambda \in [\lambda_c - \text{FWHM}/2, \lambda_c + \text{FWHM}/2]$.
- **Nearest Band** — nilai reflektansi pada panjang gelombang terdekat dengan pusat kanal: $R_b = R(\lambda_{\text{nearest}})$.
- **Gaussian Weighting** — rata-rata tertimbang Gaussian di sekitar pusat kanal: $R_b = \sum w(\lambda) \cdot R(\lambda) / \sum w(\lambda)$, dengan $w(\lambda) = \exp(-\frac{1}{2} \cdot ((\lambda - \lambda_c)/\sigma)^2)$ dan $\sigma = \text{FWHM} / 2,355$.

dengan R_b reflektansi kanal sensor, $R(\lambda)$ reflektansi spektral pada panjang gelombang λ , λ_c pusat panjang gelombang kanal, dan FWHM lebar penuh pada setengah maksimum.

Nilai FWHM setiap kanal bukan angka yang dikarang. Nilainya berasal dari kurva respons spektral (spectral response function, SRF) resmi operator satelit — **Barsi dkk. (2014)** untuk Landsat 8/9 OLI [17] dan **ESA (2021)** untuk Sentinel-2 MSI [18]. Untuk Sentinel-2, yang dipakai buku ini, FWHM kanal red-edge sangat sempit (B5 15 nm, B6 15 nm, B7 20 nm) dibandingkan kanal lebar seperti B8 (115 nm). Perbedaan lebar inilah yang membuat ketiga metode pemetaan menghasilkan nilai berbeda pada kanal red-edge, dan perbedaan itulah yang menjadi pokok uji Bab 5.

Pustaka ini menyajikan seluruh endmember pada **satu grid panjang gelombang bersama**, yaitu 400,21–999,89 nanometer dengan 3.141 titik dan langkah 0,19 nanometer. Grid bersama itu diperlukan agar seluruh spektrum dapat dibandingkan titik demi titik dan dihitung sebagai satu matriks pada penguraian spektral. Berkas mentah dapat lebih lebar daripada grid ini — berkas Mekongga misalnya memuat 3.648 titik pada rentang 344,76–1.040,30 nanometer — dan bagian di luar grid bersama memang tidak dipakai dalam penguraian. Akses terbuka untuk riset dan pendidikan.

Dua hal perlu dicatat karena keduanya menentukan hasil pada Bab 4 dan Bab 11. **Pertama**, rentang spektral berhenti pada 1.000 nanometer. Sebabnya bukan pilihan mengolah data, melainkan **keterbatasan alat**: instrumen yang dipakai hanya mengukur cahaya tampak dan inframerah sampai sekitar 1.050 nanometer, yaitu wilayah inframerah dekat. Akibatnya endmember ini **tidak memuat wilayah inframerah gelombang pendek (shortwave infrared, SWIR)**, dan indeks apa pun yang bergantung pada SWIR — MNDWI, LSWI — tidak dapat dihitung dari pustaka ini. Batas ini bersifat fisik dan tidak dapat diatasi lewat cara mengolah data; untuk mengujinya pada Bab 15, kanal SWIR harus diambil dari citra satelit, bukan dari pustaka. **Kedua**, data diambil pada skala kanopi (canopy), bukan pada skala piksel satelit; perbedaan skala inilah yang menjelaskan cakupan hull (hull coverage) bernilai nol sebagaimana dibahas pada Bab 11.

Metode reduksi dan pemetaan disediakan melalui antarmuka program (*application programming interface*, API) pada <https://geo.its.ac.id/speclib/api/>:

- **Lima metode reduksi** (meringkas seluruh sampel per panjang gelombang): Average, Gaussian, Median, Q1, dan Q3.
- **Tiga metode pemetaan** (memindahkan spektrum laboratorium ke kanal (band) sensor): Average, Gaussian Weighting, dan Nearest Band.
- **Endpoint**: `api/endmembers` (daftar endmember), `api/methods` (daftar metode reduksi dan pemetaan), dan `api/endmembers/reduce-set` (endmember yang telah direduksi dan dipetakan ke kanal sensor tertentu).

Kombinasi lima metode reduksi dengan tiga metode pemetaan menghasilkan lima belas setelan yang diuji pada Bab 5.

B. Citra satelit

Data	Penyedia	Koleksi / versi	Resolusi	Peran dalam buku
Sentinel-2 MSI (Level-2A)	ESA — program Copernicus	COPERNICUS / S2_SR_HARMONIZED	10–20 m	Sensor utama; pemisahan varietas dan indeks air
Landsat 9 OLI-2 (Level-2)	USGS — NASA	LANDSAT/LC09/C02/T1_L2	30 m	Pembanding sensor; uji susut jarak spektral
MODIS MOD13Q1 (koleksi 061)	NASA LP DAAC	MODIS/061/MOD13Q1	250 m	Fenologi; penentuan jendela tanggal
ESA WorldCover v200	ESA	ESA/WorldCover/v200	250 m (produk dasar 10 m)	Acuan bebas untuk menilai masker padi
WorldView-2 (Level 1)	Maxar	arsip akuisisi (bukan Earth Engine)	2,06 m (MS) / 0,51 m (PAN)	Uji keunggulan resolusi dan uji lintas-sensor keempat

Seluruh citra tersedia melalui **Google Earth Engine**. Periode amatan dan tanggal akuisisi dinyatakan pada bab yang bersangkutan.

Pengakuan penyedia data secara ringkas: citra **Sentinel-2** disediakan oleh **European Space Agency (ESA)** melalui program **Copernicus**. Citra **Landsat 9** disediakan oleh **United States Geological Survey (USGS)** dan **NASA**. Produk **MODIS MOD13Q1** disediakan oleh **NASA Land Processes Distributed Active Archive Center (LP DAAC)**, dan peta tutupan lahan **ESA WorldCover** disediakan oleh **ESA**. Pengolahan dan penyaringan citra memanfaatkan platform **Google Earth Engine** beserta katalog data publiknya. Pemanfaatan data-data ini tunduk pada ketentuan lisensi masing-masing penyedia; data Copernicus, Landsat, dan MODIS umumnya berlisensi terbuka untuk penggunaan riset dan pendidikan.

Sentinel-2 adalah sensor utama karena memiliki kanal red-edge (B5, B6, B7) yang tidak dimiliki Landsat. Sembilan kanal dipakai untuk pemisahan varietas (variety), dan dua kanal tambahan — B11 dan B12 pada wilayah SWIR — diunduh khusus untuk menguji klaim bahwa empat indeks lebih baik daripada dua (Bab 15.4.1).

MODIS MOD13Q1 hanya dipakai untuk menetapkan tanggal pembungaan (flowering) dan jendela komposit (composite), bukan untuk pemetaan varietas. Alasan pembatasannya dijelaskan pada Bab 7 dan diperkuat oleh angka pada Bab 15: 51,3 persen sel berukuran 250 meter tercampur, sehingga resolusi itu tidak memadai untuk memisahkan varietas.

ESA WorldCover dipakai sebagai acuan bebas (independent reference) untuk menilai masker (mask) padi. Perlu disebutkan bahwa acuan ini beresolusi kasar dan kelasnya adalah "lahan pertanian", bukan "sawah"; konsekuensinya dibahas pada Bab 8.15 dan Bab 15.9.

WorldView-2 dipakai untuk dua hal yang tidak dapat dikerjakan sensor lain, dan pemakaiannya berbeda sifat dari keempat sensor di atas karena citranya bukan dari Earth Engine melainkan dari arsip akuisisi laboratorium.

Pertama, uji keunggulan resolusi. Satu adegan WorldView-2 beresolusi 2,06 meter diagregasi menjadi sepuluh ukuran piksel (2, 4, 6, 10, 20, 30, 60, 100, 250, dan 500 meter). Karena seluruh ukuran berasal dari satu adegan yang sama, lokasi, tanggal, sensor, sudut matahari, dan kondisi atmosfernya identik — hanya ukuran pikselnya yang berubah. Dengan demikian kemerosotan mutu yang terukur dapat diatribusikan sepenuhnya kepada ukuran piksel, tanpa tercampur pengaruh tanggal atau atmosfer. Rancangan seperti ini tidak mungkin dibuat dari Sentinel-2 atau Landsat, karena setiap resolusi berarti adegan dan tanggal yang berbeda. Hasilnya dilaporkan pada Bab 6.8.1.

Kedua, uji lintas-sensor keempat. Adegan ini dipakai untuk menguji apakah cara menilai pada Bab 13 bertahan pada sensor dengan jumlah kanal yang lebih sedikit dan resolusi yang jauh lebih halus. Hasilnya dilaporkan pada Bab 13.6.2, dan hasil itu tidak menambah keyakinan melainkan menambah satu alasan lagi mengapa data lapangan diperlukan.

Koreksi atmosfer. Produk WorldView-2 yang dipakai bertingkat LV2A dengan penanda ORStandard2A. Perlu ditegaskan bahwa "2A" di sini **bukan** tingkat 2 dalam arti reflektansi permukaan: ORStandard2A berarti *Ortho Ready Standard 2A*, yaitu citra yang sudah dikoreksi secara radiometrik dan geometrik tetapi **belum dikoreksi atmosfernya**. Oleh sebab itu koreksi atmosfer dijalankan tersendiri dengan model **6S** [19], memakai parameter atmosfer yang diambil dari jaringan **AERONET** [20] untuk lokasi dan tanggal akuisisi. Pelaksanaannya memakai **6S Natural** [21], perangkat koreksi atmosfer yang dikembangkan Laboratorium Geospasial ITS dan tersedia daring. Alasan mengapa langkah ini tidak boleh dilewati, beserta kepekaannya terhadap parameter aerosol, dijelaskan pada Bab 9.4.1.

Data mentah WorldView-2 **tidak diubah** pada tahap mana pun. Koreksi atmosfer dan agregasi ukuran piksel dikerjakan pada salinan, sehingga setiap angka pada Bab 6.8.1 dan Bab 13.6.2 dapat ditelusuri kembali ke citra asalnya.

C. Pustaka perangkat lunak

Pekerjaan ini tidak akan selesai tanpa perangkat lunak bebas dan terbuka berikut. Versi yang dicantumkan adalah versi yang benar-benar dipakai saat mengolah data.

Pustaka	Versi	Peran dalam pekerjaan ini
Python	3.14.7	Bahasa pemrograman seluruh pengolahan
NumPy	2.5.3	Operasi matriks dan larik; inti perhitungan penguraian spektral
SciPy	1.18.1	Optimasi berkendala (<code>scipy.optimize</code>) dan tapis Savitzky–Golay (<code>scipy.signal</code>)
Google Earth Engine Python API (ee)	1.7.46	Pengambilan dan penyaringan citra Sentinel-2, Landsat 9, MODIS, dan WorldCover
tifffile	2026.9.20	Membaca dan menulis berkas citra GeoTIFF

Pustaka	Versi	Peran dalam pekerjaan ini
Matplotlib	3.11.2	Peta dan grafik hasil analisis
Pillow (PIL)	12.3.0	Pengolahan berkas gambar
scikit-learn	1.9.1	Keperluan pembantu pengolahan data
LibreOffice	24.2.7.2	Penyusunan naskah dan konversi DOCX ke PDF

Implementasi FCLS ditulis sendiri. Fungsi penguraian spektral (spectral unmixing) linear (linear spectral unmixing) dengan kendala penuh (`fcls_fast`) merupakan implementasi tervektor yang ditulis khusus untuk laboratorium ini, bukan pustaka pihak ketiga. Rinciannya dijelaskan pada Bab 3.6. Sebab itu kesahihan hasil bergantung pada implementasi ini. Justru karena itulah Bab 5, Bab 12, dan Bab 13 melaporkan hasil uji yang membandingkan keluarannya lintas lima belas setelan, tiga sensor, dan dua masker — bukan sekadar satu kali jalan.

Pustaka spektral Speclib [15] juga merupakan produk laboratorium sendiri, dikelola melalui API yang disebutkan pada bagian A. Pustaka ini berperan ganda: sebagai sumber endmember **dan** sebagai penyedia lima metode reduksi serta tiga metode pemetaan yang menjadi bahan uji Bab 5.

Aplikasi LSU [16]. <https://geo.its.ac.id/lsu/>

Perangkat lunak yang menyatukan seluruh alur kerja buku ini menjadi satu layanan web: pengelolaan endmember, penguraian spektral, dan pengelolaan pekerjaan. Aplikasi ini dibangun dengan **FastAPI** (antarmuka web dan API) dan **Celery** (antrean pekerjaan), dan menyediakan:

- **Pengelolaan endmember** — unggah, daftar, rincian, penghapusan, serta reduksi satu endmember atau sekumpulan endmember.
- **Penguraian spektral (LSU)** — pengajuan pekerjaan dengan beberapa endmember sekaligus, pemeriksaan status, dan pengambilan hasil.

- **Pemetaan ke kanal sensor** — preset untuk **Landsat 8 OLI** dan **Sentinel-2 MSI**, dengan lima metode reduksi dan tiga metode pemetaan yang sama seperti yang diuji pada Bab 5.

- **Antarmuka program** pada `api/lsu/run`, `api/lsu/status/{id}`, `api/lsu/result/{id}`, dan `api/endmembers/reduce-set` — endpoint terakhir inilah yang memasok endmember tereduksi bagi seluruh pengujian pada Bab 5.

Dengan kata lain, sebagian besar hasil buku ini bergantung pada **tiga perangkat yang dikembangkan di laboratorium sendiri**: implementasi FCLS, pustaka spektral Speclib, dan aplikasi LSU. Sebab itu, untuk menilai perangkat-perangkat itu dipakai pembandingan luar — jarak spektral terhadap Landsat 9, acuan bebas ESA WorldCover, serta uji ulang dengan implementasi kedua — bukan hanya dengan konsistensi internal. Bab 15 menunjukkan bahwa pembandingan luar itulah yang menyingkap kelemahan yang tidak terlihat dari dalam.

D. Ketersediaan data dan kode

Seluruh kode, berkas hasil, dan berkas angka yang mendasari buku ini tersimpan di Laboratorium Geospasial, Departemen Teknik Geomatika, ITS, dan dapat diminta untuk keperluan pengecekan. Data mentah tidak diubah pada tahap mana pun; setiap angka pada buku ini dapat ditelusuri ke berkas hasilnya.

Basis data Speclib terbuka di <https://geo.its.ac.id/speclib/>. Citra Sentinel-2, Landsat 9, MODIS, dan ESA WorldCover tersedia ulang melalui Google Earth Engine dengan koleksi yang tercantum pada bagian B.

Aplikasi LSU tersedia di <https://geo.its.ac.id/lsu/>. Aplikasi ini dipakai secara internal laboratorium, sehingga aksesnya terbatas; permintaan akses untuk keperluan riset dan pendidikan dapat disampaikan kepada Laboratorium Geospasial, Departemen Teknik Geomatika, ITS.

Rekomendasi

Bagian ini merangkum rekomendasi yang berasal dari seluruh temuan pada Bab 1 sampai Bab 16. Rekomendasi disusun dalam tiga kelompok menurut tingkat dukungan buktinya, diikuti catatan metodologis dan usulan langkah lanjut.

Rekomendasi berdasarkan hasil pengujian

Butir-butir berikut telah diuji dengan angka dan dapat dipakai langsung.

Pertama, penilaian mutu hasil sebaiknya tidak bersandar pada RMSE atau cakupan hull. Kedua ukuran itu dapat diperbaiki melalui perlakuan yang justru menurunkan mutu hasil. Pada data yang dipakai buku ini, RMSE turun hampir enam kali lipat sementara akurasi pemisahan varietas turun hampir dua belas poin persen. Ukuran yang dapat dipakai adalah akurasi pemisahan, konsistensi urutan dominasi, persentase piksel ekstrem, dan rasio singular matriks endmember.

Kedua, rasio singular matriks endmember sebaiknya diperiksa sebelum penguraian dijalankan. Pada data ini rasio singular berkorelasi dengan akurasi pada tingkat $-0,939$ dengan nilai p di bawah $0,0001$. Pemeriksaan awal memungkinkan setelan yang tidak layak dibuang sebelum citra berukuran besar diolah.

Ketiga, akurasi pemisahan spektral perlu dibedakan dari akurasi pemetaan tematik. Pengujian dalam buku ini mengukur kemampuan membedakan spektrum, bukan kemampuan menetapkan varietas pada suatu petak. Perbedaan ini sebaiknya dinyatakan setiap kali angka dilaporkan, agar hasil tidak dibaca melebihi apa yang diukur.

Keempat, empat pendekatan berikut tidak perlu diulang tanpa alasan baru: penskalaan endmember (skalar maupun vektor), penambahan kelas non-padi, koreksi per kanal, dan ekstraksi piksel murni dari citra 30 meter. Keempatnya menaikkan angka diagnostik tanpa memperbaiki hasil. Rincian pengujiannya pada Bab 12.

Kelima, koreksi atmosfer diperlukan dan nilai AOD sebaiknya tidak dibiarkan pada nilai bawaan. Perbandingan antara endmember yang diukur di permukaan dan citra yang belum dikoreksi atmosfer tidak berada pada satuan yang sama. Pengaruhnya besar: pada adegan yang diuji,

perubahan AOD dari 0,20 menjadi 0,50 menurunkan proporsi piksel yang cocok dengan endmember dari 41,1 persen menjadi 0,1 persen.

Keterbatasan yang membatasi penerapan

Tiga keterbatasan berikut membatasi seberapa jauh hasil buku ini dapat dipakai.

Kesetaraan skala antara endmember pustaka dan piksel citra belum tercapai. Setelah koreksi atmosfer, kanal tampak berselisih di bawah 20 persen, tetapi kanal inframerah dekat berbeda sekitar dua kali. Perbedaan skala menjelaskan 89,4 persen dari selisih tersebut, dan besarnya tidak seragam antar kanal. Karena kanal inframerah dekat berperan besar dalam pemisahan varietas, ketidaksetaraan ini membatasi hasil sebelum jumlah kanal atau resolusi menjadi pertimbangan.

Jumlah kelas mendekati jumlah kanal yang tersedia. Lima kelas varietas dengan empat kanal menghasilkan derajat kebebasan efektif yang terbatas, sehingga endmember antar varietas saling berdekatan dan satu kelas dapat menyerap fraksi kelas lain. Penambahan kelas non-padi tidak menyelesaikan hal ini, karena kelas baru tersebut berperan sebagai penampung sisa, bukan pemisah yang sah.

Ukuran piksel belum sepadan dengan ukuran petak sawah. Pengukuran pada satu adegan beresolusi 2 meter yang diagregasi bertingkat memberi detail spasial tersisa sebesar 100 persen pada 2 meter, 89,7 persen pada 10 meter, 76,8 persen pada 30 meter, dan 46,4 persen pada 250 meter. Proporsi piksel yang cukup murni menurun dari 26,3 persen pada 2 meter menjadi 3,9 persen pada 250 meter. Pada saat yang sama, petak sawah di Jawa berukuran 0,1 sampai 1 hektar dengan sisi 32 sampai 100 meter. Pada piksel 30 meter, petak bersisi 32 meter meliputi sekitar 1,1 piksel.

Penilaian terhadap pemetaan tingkat varietas

Berdasarkan keterbatasan pada bagian sebelumnya, pemetaan varietas padi pada tingkat petak dengan data satelit yang tersedia saat ini belum dapat dipertanggungjawabkan secara operasional. Empat keadaan berikut mendasarinya.

1. **Ukuran piksel.** Piksel berukuran 10 sampai 30 meter pada lanskap sawah Jawa umumnya memuat lebih dari satu jenis tutupan

dalam satu piksel. Pada piksel 30 meter, petak bersisi 32 meter meliputi sekitar 1,1 piksel.

2. **Pencampuran spektral.** Karena setiap piksel merupakan campuran, fraksi hasil penguraian mengukur proporsi campuran, bukan identitas varietas pada suatu petak.

3. **Jarak spektral antar varietas.** Sejumlah pasangan varietas berjarak spektral berdekatan. Jarak IR64 dan Ciherang adalah 0,1222, sekitar dua belas kali derau citra — memadai untuk pemisahan, tetapi tanpa margin yang longgar. Akibatnya IR64 dikenali benar pada 59,7 persen kasus.

4. **Ketidaktersediaan acuan lapangan.** Tanpa data lapangan mengenai varietas, tidak tersedia dasar untuk menilai model mana yang paling tepat. Karena itu seluruh pengujian dalam buku ini mengukur kesehatan solusi, belum ketepatan pemetaan.

Perlu ditegaskan ruang lingkup penilaian di atas. Penilaian ini tidak berarti citra satelit tidak bermanfaat untuk padi. Untuk pemetaan luas panen, penentuan fase tumbuh, dan pemantauan kekeringan atau banjir pada skala kabupaten, citra beresolusi 10 sampai 30 meter memadai. Yang belum dapat dipertanggungjawabkan adalah penggunaan citra tersebut untuk menetapkan varietas pada tingkat petak.

Catatan metodologis

Satu hal dari Bab 12 perlu dicatat karena berlaku umum di luar topik buku ini.

Pada Bab 12, sebuah pengolahan ditolak karena mengubah urutan dominasi varietas. Penolakan itu sah karena urutan acuannya telah teruji pada 15 kombinasi Speclib, 5 sensor, 2 masker, 2 jendela tanggal, dan 4 skema endmember. Ketika uji yang sama dijalankan pada sensor keempat, hasilnya juga mengubah urutan dominasi. Namun penolakan pada kasus kedua tidak dapat disimpulkan, karena titik tolak pada sensor keempat tersebut belum divalidasi.

Dengan demikian, uji urutan dominasi dapat dipakai untuk menolak suatu pengolahan hanya jika urutan acuannya telah divalidasi secara independen. Jika titik tolaknya belum tervalidasi, perubahan urutan tidak memberi kesimpulan yang pasti: dapat berarti pengolahan yang merusak, dapat juga berarti titik tolaknya yang keliru sejak awal. Tanpa acuan yang

terpercaya, kedua kemungkinan itu tidak dapat dibedakan dari data yang tersedia.

Langkah lanjut yang dianjurkan

Berdasarkan seluruh pembahasan di atas, urutan pekerjaan yang dianjurkan adalah sebagai berikut.

1. Melengkapi data lapangan varietas sebelum menambah citra.

Pendataan varietas, fase, dan tanggal tanam pada sejumlah petak memberi manfaat lebih besar daripada penambahan citra tanpa acuan. Tanpa langkah ini, pengujian lanjutan hanya menambah keyakinan pada solusi yang belum tentu tepat.

2. Mengukur endmember padi pada lokasi dan fase yang sama dengan citra. Selisih skala sebesar 89,4 persen tersebut diduga berasal dari perbedaan lokasi dan keadaan kanopi, dan dugaan ini dapat diuji secara langsung.

3. Menjadikan petak sebagai unit analisis, bukan piksel. Karena satu petak jauh lebih besar daripada satu piksel, fraksi sebaiknya dijumlahkan pada tingkat petak, dengan batas petak dari data lapangan atau citra beresolusi sangat tinggi.

4. Mengelompokkan varietas yang jarak spektralnya berdekatan. IR64 dan Ciherang dengan jarak 0,1222 sebaiknya diperlakukan sebagai satu kelompok, atau dipisahkan dengan data tambahan.

5. Menyertakan pernyataan ketidakpastian pada setiap peta yang dilaporkan. Peta varietas perlu disertai keterangan mengenai hal-hal yang belum tervalidasi, agar tidak dibaca sebagai hasil yang sudah terverifikasi.

Sebagai penutup, hasil yang paling berguna dari buku ini adalah perumusan batas mengenai apa yang belum dapat dikerjakan dengan data yang tersedia. Perumusan batas tersebut menjadi titik awal yang lebih baik daripada pemrosesan citra tambahan tanpa acuan. Apabila pemetaan varietas tingkat petak dapat dilakukan pada masa mendatang, langkah pertamanya adalah pendataan lapangan.

Glosarium

Daftar istilah yang dipakai dalam buku ini, disusun menurut abjad. Istilah teknis diberikan dalam bahasa Indonesia beserta padanan Inggrisnya; istilah yang lazim dipakai dalam bentuk aslinya (misalnya *endmember*, *hull*) dicantumkan apa adanya. Nomor dalam kurung menunjukkan bab tempat istilah itu dibahas lebih rinci.

Istilah	Padanan Inggris	Arti
akurasi pengguna	<i>user's accuracy</i>	Bagian piksel yang benar di antara semua piksel yang disebut termasuk suatu kelas. Mengukur seberapa dapat dipercaya label yang diberikan. (8)
akurasi produsen	<i>producer's accuracy</i>	Bagian piksel suatu kelas yang benar-benar terdeteksi. Setara dengan <i>recall</i> . (8)
ambang	<i>threshold</i>	Nilai batas yang memisahkan dua keadaan, misalnya piksel padi dari bukan padi. (7, 8)
amplitudo	<i>amplitude</i>	Selisih antara nilai puncak dan nilai dasar pada kurva EVI, dipakai sebagai skala relatif untuk menentukan fase tumbuh. (7)
basis (nilai dasar)	<i>baseline</i>	Nilai terendah kurva EVI pada satu piksel, dihitung sebagai persentil ke-10, yang menjadi acuan perhitungan amplitudo. (7)
bera	<i>fallow</i>	Keadaan sawah tanpa tanaman, antara panen dan tanam berikutnya. (7, 9)
cakupan hull	<i>hull coverage</i>	Bagian piksel yang jatuh di dalam <i>convex hull</i> <i>endmember</i> . Nilai nol berarti tidak ada piksel

Istilah	Padanan Inggris	Arti
		yang tercakup. (4, 11)
derau	<i>noise</i>	Gangguan acak pada nilai reflektansi yang tidak berasal dari objek yang diamati. (5, 13)
deret waktu	<i>time series</i>	Rangkaian pengamatan pada waktu berbeda yang dipakai untuk mengikuti perubahan fenologi. (7)
endmember	<i>endmember</i>	Spektrum murni satu jenis penutup lahan, di sini satu varietas padi, yang menjadi titik sudut ruang campuran. (2, 4)
fase generatif	<i>generative phase</i>	Tahap tumbuh dari inisiasi malai sampai pembungaan, ketika spektrum padi paling khas. (7)
fase vegetatif	<i>vegetative phase</i>	Tahap tumbuh dari tanam sampai sebelum inisiasi malai. (7)
fenologi	<i>phenology</i>	Ilmu tentang waktu dan urutan tahap tumbuh tanaman sepanjang musim. (7)
FCLS	<i>fully constrained least squares</i>	Penguraian spektral linear dengan dua kendala sekaligus: fraksi tidak negatif dan jumlahnya satu. (3)
fraksi	<i>fraction</i>	Bagian luas satu penutup lahan di dalam satu piksel; nilainya 0 sampai 1 dan seluruh fraksi berjumlah 1. (2, 3)
genangan	<i>inundation</i>	Air yang menggenangi permukaan sawah, penanda kuat keberadaan sawah. (7)
glosarium	<i>glossary</i>	—
hull	<i>convex hull</i>	Selubung cembung terkecil yang memuat

Istilah	Padanan Inggris	Arti
		seluruh endmember; campuran yang sah berada di dalamnya. (2, 11)
indeks vegetasi	<i>vegetation index</i>	Ukuran turunan dari beberapa kanal yang menonjolkan sifat vegetasi, misalnya NDVI dan EVI. (5, 7)
inframerah gelombang pendek	<i>shortwave infrared (SWIR)</i>	Wilayah spektrum sekitar 1.500–2.500 nm yang peka terhadap kandungan air pada daun dan tanah. (6, 15)
irigasi bergilir	<i>rotational irrigation</i>	Sistem pengairan yang mengalirkan air ke blok petak secara bergantian, sehingga waktu tanam bergeser antarpetak. (7)
jarak spektral	<i>spectral distance</i>	Ukuran ketidakmiripan dua spektrum berdasarkan selisih nilainya pada setiap kanal. (4, 5)
jendela komposit	<i>composite window</i>	Rentang tanggal yang dipakai untuk menggabungkan beberapa perekaman menjadi satu citra. (7, 9)
kanal	<i>band</i>	Rentang panjang gelombang tertentu yang direkam sensor sebagai satu nilai per piksel. (1, 6)
kanopi	<i>canopy</i>	Tajuk tanaman, bagian padi yang terlihat dari atas dan paling banyak menentukan spektrum yang terekam. (4, 6)
kappa Cohen	<i>Cohen's kappa</i>	Ukuran kesesuaian dua penilaian yang telah memperhitungkan kesepakatan yang terjadi secara kebetulan. (8)

Istilah	Padanan Inggris	Arti
kelimpahan	<i>abundance</i>	Padanan lain <i>fraksi</i> , yaitu seberapa banyak suatu penutup lahan hadir di dalam satu piksel. (2)
kendala non-negatif	<i>non-negativity constraint</i>	Syarat bahwa fraksi tidak boleh bernilai negatif, karena luas tidak dapat negatif. (2, 3)
klorofil	<i>chlorophyll</i>	Pigmen daun yang menyerap cahaya merah dan memantulkan inframerah dekat; sumber utama kontras vegetasi. (6)
komposit	<i>composite</i>	Citra gabungan dari beberapa perekaman pada rentang tanggal tertentu. (7, 9)
korelasi peringkat	<i>rank correlation</i>	Ukuran hubungan dua peubah berdasarkan urutan nilainya, tidak menuntut hubungan yang linear. (13)
masker	<i>mask</i>	Lapisan yang menandai piksel mana yang dipakai dalam analisis, di sini piksel padi. (8)
masker liar	<i>naive mask</i>	Pembandingan yang menyatakan semua piksel sebagai padi tanpa analisis apa pun; dipakai untuk menguji apakah F1 dapat dipercaya. (8)
matriks kekeliruan	<i>confusion matrix</i>	Tabel empat sel (benar positif, salah positif, salah negatif, benar negatif) yang menjadi dasar seluruh ukuran akurasi. (8)
MCC	<i>Matthews correlation coefficient</i>	Ukuran akurasi tunggal yang memakai keempat sel matriks kekeliruan; bernilai nol bila tidak ada informasi. (8)

Istilah	Padanan Inggris	Arti
MNDWI	<i>modified normalised difference water index</i>	Indeks yang menonjolkan air permukaan dengan memakai kanal hijau dan inframerah gelombang pendek. (15)
musim tanam	<i>cropping season</i>	Satu daur lengkap dari tanam sampai panen. (7)
NDVI	<i>normalised difference vegetation index</i>	Indeks vegetasi paling lazim, memakai kanal merah dan inframerah dekat; jenuh pada tutupan rapat. (5, 7)
EVI	<i>enhanced vegetation index</i>	Indeks vegetasi yang dirancang mengurangi kejenuhan NDVI, dipakai untuk menentukan puncak kurva tumbuh. (7)
LSWI	<i>land surface water index</i>	Indeks yang menonjolkan kandungan air permukaan dan tanaman, memakai inframerah dekat dan gelombang pendek. (15)
NDFI	<i>normalised difference flooding index</i>	Indeks yang dipakai untuk mengenali penggenapan sawah. (7)
nilai singular	<i>singular value</i>	Ukuran "kekuatan" arah utama sebuah matriks, diperoleh dari penguraian nilai singular. (2, 4)
persentil	<i>percentile</i>	Nilai di bawahnya terdapat sekian persen amatan; dipakai untuk menyatakan sebaran tanggal pembungaan. (7)
piksel ekstrem	<i>extreme pixel</i>	Piksel yang seluruh fraksinya hampir nol atau hampir satu, tanda solusi terdorong ke batas ruang yang sah. (4, 13)
piksel murni	<i>pure pixel</i>	Piksel yang dianggap hanya memuat satu jenis

Istilah	Padanan Inggris	Arti
		penutup lahan, tanpa campuran. (4)
plafon F1	<i>F1 ceiling</i>	Nilai F1 tertinggi yang dapat dicapai tanpa membawa informasi apa pun; naik seiring makin tidak seimbangnya kelas. (8)
presisi	<i>precision</i>	Bagian piksel yang benar di antara semua piksel yang disebut termasuk suatu kelas. (8)
prevalensi	<i>prevalence</i>	Bagian luas suatu kelas terhadap seluruh area; menentukan seberapa menyesatkan F1. (8)
puncak (EVI)	<i>EVI peak</i>	Titik tertinggi kurva EVI satu piksel, dipakai sebagai penanda waktu pembungaan. (7)
rasio singular	<i>singular-value ratio</i>	Perbandingan nilai singular terbesar terhadap terkecil pada matriks endmember; mengukur seberapa "gepeng" ruang spektrum yang tersedia. (2, 4)
recall	<i>recall</i>	Bagian piksel suatu kelas yang benar-benar terdeteksi; setara akurasi produsen. (8)
reflektansi	<i>reflectance</i>	Bagian cahaya datang yang dipantulkan permukaan, dinyatakan 0 sampai 1. (1, 2)
red-edge	<i>red-edge</i>	Bagian kurva spektrum antara cahaya merah dan inframerah dekat yang naik sangat tajam pada vegetasi; hanya terekam oleh sensor berkanal khusus. (6)
reduksi	<i>reduction</i>	Peringkasan seluruh sampel spektrum

Istilah	Padanan Inggris	Arti
		laboratorium menjadi satu spektrum wakil per panjang gelombang. (5)
simpleks	<i>simplex</i>	Daerah geometris tempat seluruh fraksi berjumlah satu dan tidak negatif. (2, 3)
sirkularitas	<i>circularity</i>	Cacat penalaran ketika acuan penilaian didefinisikan oleh besaran yang sedang dinilai, sehingga hasilnya selalu tampak baik. (8, 15)
Speclib	<i>spectral library</i>	Basis data spektrum hasil pengukuran spektoradiometer yang dikelola Laboratorium Geospasial ITS. (4, 16)
spektoradiometer	<i>spectroradiometer</i>	Alat pengukur reflektansi per panjang gelombang secara rinci, dipakai untuk membangun pustaka spektral. (4)
sudut spektral	<i>spectral angle (SAM)</i>	Ukuran kemiripan bentuk dua spektrum, tidak terpengaruh perbedaan skala atau kecerahannya. (4)
tapis Savitzky–Golay	<i>Savitzky–Golay filter</i>	Penghalus kurva yang mempertahankan bentuk puncak, dipakai pada kurva EVI sebelum puncak dicari. (7)
uji kebermaknaan	<i>significance test</i>	Uji statistik yang menilai apakah suatu hubungan cukup kuat untuk tidak dianggap kebetulan. (13)
validasi lapangan	<i>field validation</i>	Pemeriksaan hasil terhadap keadaan sebenarnya yang diukur di lapangan. Belum dilaksanakan pada pekerjaan ini. (10, 14)

Istilah	Padanan Inggris	Arti
varietas	<i>variety</i>	Golongan tanaman padi hasil pemuliaan dengan sifat khas, misalnya Ciherang, IR64, Inpari32, Mekongga. (1, 4)

Seluruh rujukan di bawah ini dipakai sebagai sitasi bernomor di dalam teks. Setiap rujukan telah diverifikasi keberadaannya melalui pengenal digital (DOI) atau arsip resmi penerbit.

- [1] Keshava, N., & Mustard, J. F. (2002). Spectral unmixing. *IEEE Signal Processing Magazine*, 19(1), 44-57. doi:10.1109/79.974727
- [2] Heinz, D. C., & Chang, C.-I. (2001). Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(3), 529-545. doi:10.1109/36.911111
- [3] Boardman, J. W. (1993). Automating spectral unmixing of AVIRIS data using convex geometry concepts. *Summaries of the 4th Annual JPL Airborne Geoscience Workshop*, 1, 11-14. ntrs.nasa.gov/citations/19950017428
- [4] Boschetti, M., Busetto, L., Manfron, G., Laborte, A., Asilo, S., Pazhanivelan, S., & Nelson, A. (2017). PhenoRice: A method for automatic extraction of spatio-temporal information on rice crops using satellite data time series. *Remote Sensing of Environment*, 194, 347-365. doi:10.1016/j.rse.2017.03.029
- [5] Huete, A., Didan, K., Miura, T., Rodriguez, E. P., Gao, X., & Ferreira, L. G. (2002). Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83(1-2), 195-213. doi:10.1016/S0034-4257(02)00096-2
- [6] Forkuor, G., Dimobe, K., Serme, I., & Tondoh, J. E. (2018). Landsat-8 vs. Sentinel-2: examining the added value of Sentinel-2's red-edge bands to land-use and land-cover mapping in Burkina Faso. *GIScience & Remote Sensing*, 55(3), 331-354. doi:10.1080/15481603.2017.1370169
- [7] Qiu, S., He, B., Yin, C., & Liao, Z. (2017). Assessments of Sentinel-2 vegetation red-edge spectral bands for improving land cover classification. *ISPRS Archives, XLII-2/W7*, 871-874. doi:10.5194/isprs-archives-XLII-2-W7-871-2017
- [8] ESA. (2024). Sentinel-2: Plant health / red-edge bands. European Space Agency. esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2
- [9] Somers, B., Asner, G. P., Tits, L., & Coppin, P. (2011). Endmember variability in spectral mixture analysis: A review. *Remote Sensing of Environment*, 115(7), 1603-1616. doi:10.1016/j.rse.2011.03.003

- [10] Wu, X., dkk. (2024). A novel red-edge vegetable index for paddy rice mapping based on Sentinel-1/2 and GF-6 images. *International Journal of Digital Earth*. doi:10.1080/17538947.2024.2398068
- [11] Chang, C.-I., & Li, H.-C. (2022). Analytical fully constrained least squares linear spectral mixture analysis. Dalam *Advances in Hyperspectral Image Processing Techniques* (hlm. 404-421). Wiley. doi:10.1002/9781119687788.ch14
- [12] Heinz, D. C., Chang, C.-I., & Althouse, M. L. G. (1999). Fully constrained least-squares based linear unmixing. *IGARSS'99*, 2, 1401-1403. doi:10.1109/IGARSS.1999.774644
- [13] Cipta, I. M., Jaelani, L. M., & Sanjaya, H. (2022). Identification of paddy varieties from Landsat 8 satellite image data using spectral unmixing method in Indramayu Regency, Indonesia. *ISPRS International Journal of Geo-Information*, 11(10), 510. doi:10.3390/ijgi11100510
- [14] Cipta, I. M., Jaelani, L. M., & Sanjaya, H. (2024). A phenology-based linear spectral unmixing method for rice varieties identification from Landsat 8 satellite image in Ngawi District, East Java, Indonesia. *Biodiversitas Journal of Biological Diversity*, 25(4), 1691-1702. doi:10.13057/biodiv/d250439
- [15] Jaelani, L. M. (2025). *Speclib: Pustaka spektral terbuka Laboratorium Geospasial ITS [Basis data]*. Surabaya: Laboratorium Geospasial, Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember. <https://geo.its.ac.id/speclib/>
- [16] Jaelani, L. M. (2026). *LSU Controller: Aplikasi penguraian spektral linear (linear spectral unmixing) [Perangkat lunak]*. Surabaya: Laboratorium Geospasial, Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember. <https://geo.its.ac.id/lsu/>
- [17] Barsi, J. A., Lee, K., Kvaran, G., Markham, B. L., & Pedelty, J. A. (2014). The spectral response of the Landsat-8 Operational Land Imager. *Remote Sensing*, 6(10), 10232-10251. doi:10.3390/rs61010232
- [18] European Space Agency. (2021). Sentinel-2 MSI spectral response functions (SRF) v3.0 [Dokumentasi teknis]. ESA. <https://sentinels.copernicus.eu/web/sentinel/user-guides/sentinel-2-msi>
- [19] Vermote, E. F., Tanre, D., Deuze, J. L., Herman, M., & Morcrette, J.-J. (1997). Second simulation of the satellite signal in the solar spectrum, 6S: An overview. *IEEE Transactions on Geoscience and Remote Sensing*, 35(3), 675-686. doi:10.1109/36.581987

[20] Holben, B. N., Eck, T. F., Slutsker, I., Tanre, D., Buis, J. P., Setzer, A., dkk. (1998). AERONET: A federated instrument network and data archive for aerosol characterization. *Remote Sensing of Environment*, 66(1), 1-16. doi:10.1016/S0034-4257(98)00031-5

[21] Jaelani, L. M. (2026). 6S Natural: Perangkat koreksi atmosfer untuk citra satelit berbasis model 6S [Perangkat lunak]. Surabaya: Laboratorium Geospasial, Departemen Teknik Geomatika, Institut Teknologi Sepuluh Nopember. <https://geo.its.ac.id/6Snatural/>